



MODELO PREDICTIVO DE HUMEDAD EN INVERNADEROS MEDIANTE INFERENCIA DIFUSA APLICANDO MÉTODOS DE OPTIMIZACIÓN

Sebastian Camilo Vanegas Ayala

UNIVERSIDAD DISTRITAL FRANCISCO JOSÉ DE CALDAS
FACULTAD DE INGENIERÍA
MAESTRÍA EN CIENCIAS DE LA INFORMACIÓN Y LAS COMUNICACIONES
ÉNFASIS EN INGENIERÍA DE SOFTWARE
BOGOTÁ D.C., COLOMBIA
2022

MODELO PREDICTIVO DE HUMEDAD EN INVERNADEROS MEDIANTE INFERENCIA DIFUSA APLICANDO MÉTODOS DE OPTIMIZACIÓN

Sebastian Camilo Vanegas Ayala

Director:

Ing. Julio Barón Velandia PhD

Grupo de investigación:

Interoperabilidad Tecnológica y Semántica

INTECSE

UNIVERSIDAD DISTRITAL FRANCISCO JOSÉ DE CALDAS
FACULTAD DE INGENIERÍA
MAESTRÍA EN CIENCIAS DE LA INFORMACIÓN Y LAS COMUNICACIONES
ÉNFASIS EN INGENIERÍA DE SOFTWARE
BOGOTÁ D.C., COLOMBIA
2022

Dedicada con amor a mi familia, mi pareja, amigos y todas las personas que me han apoyado y aportado en cada paso.

Agradecimientos

Agradezco a Dios y a su espíritu creador, por brindarme las herramientas, los momentos y las personas que han contribuido en el desarrollo de este camino investigativo.

De igual forma a mi familia por el apoyo incondicional, el acompañamiento y amor constante que me llena de fuerzas cada día y han sido un pilar fundamental para el trabajo realizado.

A la Universidad Distrital Francisco José de Caldas, por brindar un espacio de crecimiento personal e intelectual y dar las herramientas y recursos para terminar a satisfacción los estudios posgraduales en la maestría, adquiriendo capacidades investigativas y sociales para la actividad profesional.

A los docentes de la maestría que han acompañado la formación posgradual y a los miembros del grupo de investigación INTECSE por la retroalimentación y apoyo durante el desarrollo del proyecto investigativo.

Y en especial, a mi Director, Julio Barón Velandia, por el acompañamiento y seguimiento en todas las etapas del proceso investigativo, por el ánimo constante para lograr las metas propuestas y el apoyo en el crecimiento profesional y personal.

Resumen

Este documento presenta los resultados para predicción humedad relativa interna en invernaderos, permitiendo describir su comportamiento de forma fácil, sencilla e interpretable para personas interesadas en actividades agrícolas, sin requerir conocimiento específico sobre el manejo de herramientas de procesamiento de colecciones de datos. Se definen sistemas de inferencia difusa optimizados mediante varios métodos y algoritmos, que obtienen el mayor grado de interpretabilidad y precisión para facilitar el seguimiento y control, implementado mediante herramientas computacionales en ambientes de invernadero. La solución proporciona dos modelos de sistemas de inferencia difusa, dependiendo de los datos disponibles en el entorno de invernadero, optimizados mediante algoritmo genético y de punto interior aplicando una estrategia híbrida, uno de los modelos se basa en datos históricos de humedad relativa y usa sistemas de inferencia difusa tipo ANFIS, el otro basado en variables correlacionadas con la humedad relativa a partir de sistemas de inferencia difusa tipo Mamdani, ambos proporcionan resultados con alto grado de precisión e interpretabilidad.

Palabras clave

Conjunto difuso; humedad; invernadero; método de optimización; modelo de predicción

TABLA DE CONTENIDO

1. INTRODUCCIÓN	1
2. PROBLEMA DE INVESTIGACIÓN	3
2.1. PLANTEAMIENTO DEL PROBLEMA	3
2.2. FORMULACIÓN DEL PROBLEMA	4
2.3. SISTEMATIZACIÓN DEL PROBLEMA	4
3. OBJETIVOS	5
3.1. OBJETIVO GENERAL	5
3.2. OBJETIVOS ESPECÍFICOS	5
4. JUSTIFICACIÓN	7
5. MARCO DE REFERENCIA	9
5.1. MARCO CONCEPTUAL	9
5.1.1. Sistemas de inferencia difusa	9
5.1.2. Métodos de optimización	16
5.1.3. Medición del error en la predicción	19
5.2. MARCO TEÓRICO	21
5.2.1. Predicción de humedad climática	21
5.2.2. Predicción de humedad en invernaderos	22
5.2.3. Predicción de humedad en invernaderos con sistemas de inferencia difusa	25
5.2.4. Funciones de pertenencia que describen humedad relativa en conjuntos difusos	32
6. HIPÓTESIS	35
7. MARCO METODOLÓGICO	37
7.1. ADQUISICIÓN DE DATOS	37
7.1.1. Parametrización de variables	38
7.1.2. Adquisición de datos	38
7.2. ANÁLISIS DE LOS DATOS	38
7.2.1. Caracterización de las variables	38

7.2.2. Análisis de correlación de las variables	39
7.3. CONSTRUCCIÓN DEL MODELO	39
7.3.1. Determinación de las variables de entrada	39
7.3.2. Elaboración de prototipos desde diferentes perspectivas	39
7.3.3. Implementación mecanismos de optimización	39
7.4. VALIDACIÓN DEL MODELO	40
7.4.1. Medición del grado de precisión	40
7.4.2. Comparación del grado de precisión e interpretabilidad	40
7.5. MODELO DE PROCESO EVOLUTIVO BASADO EN PROTOTIPOS	40
8. LIMITACIONES	43
9. DESARROLLO DE LA INVESTIGACIÓN	45
9.1. ADQUISICIÓN Y PREPROCESAMIENTO DE DATOS	45
9.1.1. Adquisición de datos	45
9.1.2. Preprocesamiento de datos	46
9.2. ANÁLISIS DE LOS DATOS	46
9.2.1. Estadística exploratoria de los datos	46
9.2.2. Análisis de correlación de las variables	48
9.3. CONSTRUCCIÓN DEL MODELO	53
9.3.1. Configuración sistemas de inferencia difusa	53
9.3.2. Configuración mecanismos de optimización	57
9.3.3. Configuración mecanismos de agrupamiento difuso	58
9.4. VALIDACIÓN DEL MODELO	58
9.4.1. Modelo basado en datos históricos de humedad	58
9.4.2. Modelo basado en variables correlacionadas	70
9.5. PROTOTIPO SOFTWARE	83
9.5.1. Funcionamiento del prototipo	83
9.5.2. Despliegue del prototipo	86
10.CONCLUSIONES	89
10.1. Principales Aportes	90
11.PROSPECTIVA DEL TRABAJO DE GRADO	91
11.1. PRODUCTOS	91
11.1.1. ARTÍCULOS	91
11.1.2. PONENCIAS EN EVENTOS CIENTÍFICOS	92
11.1.3. REGISTRO DE SOFTWARE Y PROPIEDAD INTELECTUAL	92
11.2. RECOMENDACIONES Y TRABAJOS FUTUROS	92
11.2.1. RECOMENDACIONES	92
11.2.2. TRABAJOS FUTUROS	92

<i>TABLA DE CONTENIDO</i>	VII
GLOSARIO	95
BIBLIOGRAFÍA	97

LISTA DE FIGURAS

5.1. Sistema de inferencia difusa convencional.	10
5.2. Ejemplo de Inferencia en un sistema de inferencia difusa de tipo Mamdani.	11
5.3. Inferencia en un sistema de inferencia difusa de tipo Sugeno.	12
5.4. Sistema de razonamiento difuso tipo 1 y su equivalente ANFIS de tipo 1. a) Razonamiento difuso de tipo 1. b) Equivalente ANFIS de tipo 1.	13
5.5. Funcionamiento del sistema de inferencia Tsukamoto.	15
7.1. Técnica metodológica aplicada.	37
7.2. El modelo de proceso para la creación de prototipos.	41
9.1. Comparación valores reales y de los modelos basados en datos históricos en la fase de entrenamiento.	64
9.2. Comparación valores reales y de los modelos basados en datos históricos en la fase de validación.	65
9.3. Error valores reales con los de los modelos basados en datos históricos en la fase de entrenamiento.	65
9.4. Error valores reales con los de los modelos basados en datos históricos en la fase de validación.	66
9.5. Conjuntos difusos modelo predicción basado en datos históricos.	67
9.6. Reglas del sistema de inferencia para modelo basado en datos históricos.	68
9.7. Superficie de reglas modelo predicción basado en datos históricos.	68
9.8. Estructura ANFIS para modelo basado en datos históricos.	69
9.9. Comparación valores reales y de los modelos basados en variables correlacionadas en la fase de entrenamiento.	76
9.10. Comparación valores reales y de los modelos basados en variables correlacionadas en la fase de validación.	77
9.11. Error valores reales con los de los modelos basados en variables correlacionadas en la fase de entrenamiento.	77
9.12. Error valores reales con los de los modelos basados en variables correlacionadas en la fase de validación.	78
9.13. Conjuntos difusos temperatura modelo predicción basado en variables correlacionadas.	79

9.14. Conjuntos difusos concentración de CO_2 modelo predicción basado en variables correlacionadas.	80
9.15. Conjuntos difusos humedad del suelo modelo predicción basado en variables correlacionadas.	80
9.16. Conjuntos difusos humedad relativa interna modelo predicción basado en variables correlacionadas.	81
9.17. Reglas del sistema de inferencia para modelo basado en variables correlacionadas.	81
9.18. Superficie de reglas modelo predicción basado en datos históricos.	82
9.19. Carga de datos.	84
9.20. Prototipo de visualización, predicción de humedad interna en invernaderos.	84
9.21. Prototipo de visualización, conjuntos difusos.	85
9.22. Prototipo de visualización, reglas de inferencia.	86
9.23. Repositorio de despliegue prototipo de visualización.	86
9.24. Servidor de aplicaciones Web.	87
9.25. Prototipo como aplicación Web.	87

LISTA DE TABLAS

5.1. Predicción de humedad climática.	21
5.2. Predicción de humedad en invernaderos.	23
5.3. Modelos de predicción en invernaderos que involucran humedad usando sistemas de inferencia difusa.	26
5.4. Funciones de pertenencia usadas para describir humedad relativa.	32
9.1. Análisis exploratorio de las variables en invernadero con cultivos de habichuelas.	47
9.2. Análisis exploratorio de las variables en invernadero sin cultivos.	47
9.3. Matriz de correlación de Pearson de las variables en invernadero con cultivo de habichuelas.	49
9.4. Matriz de correlación de Spearman de las variables en invernadero con cultivo de habichuelas.	50
9.5. Matriz de correlación de Pearson de las variables en invernadero sin cultivos.	51
9.6. Matriz de correlación de Spearman de las variables en invernadero sin cultivos.	51
9.7. Parámetros sistema de inferencia difusa tipo Mamdani.	53
9.8. Parámetros sistema de inferencia difusa tipo Sugeno.	54
9.9. Parámetros sistema de inferencia difusa tipo ANFIS.	54
9.10. Parámetros algoritmo genético.	57
9.11. Parámetros algoritmo de punto interior.	57
9.12. Parámetros método de agrupamiento difuso FCMClustering.	58
9.13. Valores de error para las ejecuciones de los modelos de predicción basados en datos históricos de humedad.	59
9.14. Valores promedio de error para las ejecuciones de los modelos de predicción basados en datos históricos.	63
9.15. Análisis de precisión e interpretabilidad para modelos basados en datos históricos.	66
9.16. Valores de error para las ejecuciones de los modelos de predicción basados en variables correlacionadas. Elaboración Propia.	71
9.17. Valores promedio de error para las ejecuciones de los modelos de predicción basados en variables correlacionadas. Elaboración Propia.	75
9.18. Análisis de precisión e interpretabilidad para modelos basados en variables correlacionadas.	78

Capítulo 1

INTRODUCCIÓN

El incremento de la demanda de productos agrícolas con alto grado de calidad requiere la práctica de técnicas innovadoras de gestión en diferentes ámbitos de los sistemas de producción (Shamshiri, 2017), esto ha propiciado el desarrollo de invernaderos controlados computacionalmente para producir alimentos en menor tiempo y mayor rendimiento (Gondchawar & Kawitkar, 2016).

El ambiente controlado verifica el comportamiento de las variables y mantiene sus valores en los rangos adecuados para el cultivo. La humedad presenta un comportamiento dinámico no lineal con alto grado de complejidad para su control, por lo tanto, al predecir su comportamiento de forma cuantitativa y cualitativa se puede mejorar el rendimiento de las acciones de control y aumentar el grado de entendimiento por parte de los usuarios (Nachidi y col., 2006).

Se puede obtener un modelo fácilmente interpretable para el usuario y con alto grado de precisión que posteriormente puede ser usado para la implementación de procesos de control con mayor eficiencia describiendo el comportamiento de la humedad relativa interna aplicando sistemas de inferencia difusa y métodos de optimización.

Este documento se divide en los siguientes capítulos: problema de investigación, conformado por el planteamiento, formulación y sistematización del problema, objetivo general y específicos, justificación, marco de referencia dividido en marco conceptual y teórico, la hipótesis investigativa, el marco metodológico, limitaciones, desarrollo de la investigación, donde se aborda la adquisición, preprocesamiento y análisis de los datos, la construcción y validación del modelo y su implementación en un prototipo software y finalmente las conclusiones, las perspectivas del trabajo realizado y las referencias bibliográficas.

Capítulo 2

PROBLEMA DE INVESTIGACIÓN

2.1. PLANTEAMIENTO DEL PROBLEMA

El estudio y diseño de controladores ambientales eficientes requiere conocimiento a priori de los modelos, estos están relacionados con las influencias externas como la radiación solar, la temperatura y humedad del aire exterior, etc. y con los mecanismos de actuación como ventilación, refrigeración, calefacción, entre otras (Hurtado y col., 2010). Debido a la naturaleza sensible de la reproducción de las plantas en un invernadero y la interacción compleja de las variables dentro del mismo, cobra gran importancia comprender las características y parámetros del entorno, donde el control preciso de la humedad puede proporcionar un ambiente de crecimiento favorable para las plantas, manteniendo sus valores en los rangos predeterminados para obtener mejores condiciones del medio de crecimiento (Heidari & Khodadadi, 2017).

La humedad tanto interna como externa de un invernadero muestra un comportamiento dinámico no lineal, siendo la humedad interna la variable de interés para el control y modelado de un invernadero, se requieren herramientas que permitan describir su comportamiento (Caponetto y col., 2000; Hurtado y col., 2010). Enfoques de inteligencia artificial como redes neuronales junto con inferencia difusa se han utilizado para modelar el comportamiento dinámico, mediante la síntesis de un modelo robusto que describa su comportamiento y pueda predecirlo (Lachouri y col., 2016).

Los modelos descritos por sistemas de inferencia difusa proveen alta interpretabilidad, pero no garantizan un alto grado de precisión, es por ello que su optimización es necesaria para aumentar el rendimiento mediante el uso de diferentes métodos que ajusten sus parámetros (Lenka & Mohapatra, 2015; Trabelsi y col., 2007). Partiendo de una revisión de la literatura científica se encuentra que los modelos se centran en un alto grado de precisión (Outanoute y col., 2015) o de interpretabilidad

(Trabelsi y col., 2007), pero no buscan ambos objetivos simultáneamente, obstaculizando al usuario final el entendimiento de los resultados mientras se conserva un alto grado de confianza en los mismos.

2.2. FORMULACIÓN DEL PROBLEMA

¿Cómo predecir los valores de humedad relativa interna requeridos en ambientes de invernadero con alta interpretabilidad y precisión, empleando métodos de optimización en sistemas de inferencia difusa para aportar al control y seguimiento del desarrollo de cultivos?

2.3. SISTEMATIZACIÓN DEL PROBLEMA

- ¿Cómo las variables en ambientes de invernadero determinan el comportamiento de la humedad relativa?
- ¿Qué configuración de sistemas de inferencia difusa usando las variables en ambientes de invernadero permiten la predicción de valores de humedad relativa con el mayor grado de precisión?
- ¿Qué métodos de optimización pueden ser aplicables en sistemas de inferencia difusa para aumentar su nivel de precisión?
- ¿Qué combinación de sistema de inferencia difusa y método de optimización brinda mayor grado de precisión e interpretabilidad en la predicción de valores de humedad relativa?
- ¿Cómo presentar la predicción de valores de humedad relativa en invernaderos al usuario de forma sencilla y clara, para su posterior uso en procesos de control y seguimiento en el desarrollo de cultivos?

Capítulo 3

OBJETIVOS

3.1. OBJETIVO GENERAL

Establecer un modelo predictivo de valores de humedad relativa interna en un invernadero con alta precisión e interpretabilidad, mediante el uso de sistemas de inferencia difusa optimizados por métodos heurísticos y exactos, para facilitar a los usuarios del invernadero la descripción clara y sencilla de su comportamiento.

3.2. OBJETIVOS ESPECÍFICOS

- Determinar la variación del comportamiento de la humedad relativa a partir de las variables en ambientes de invernadero mediante un análisis estadístico y de correlación para establecer su grado de relevancia en la predicción.
- Elaborar modelos de predicción para los valores de humedad relativa, mediante el uso de diversos sistemas de inferencia difusa y variables del ambiente de invernadero, ofreciendo diferentes niveles de interpretación para el usuario.
- Aumentar el grado de precisión de los modelos elaborados, aplicando métodos de optimización heurísticos y exactos, para incrementar el grado de confianza de los modelos de predicción.
- Determinar el grado de significancia del resultado para cada modelo, usando técnicas estadísticas como la prueba t para dos muestras, con el fin de identificar el modelo que presente mayor precisión e interpretabilidad.
- Desarrollar un prototipo software para la predicción de valores de humedad relativa en un invernadero, usando el modelo con mayor grado de precisión e interpretabilidad, facilitando la interacción del usuario con el modelo.

Capítulo 4

JUSTIFICACIÓN

Conocer los valores de humedad interna y externa en un invernadero permite describir el rendimiento del cultivo durante todo su ciclo de desarrollo, estos valores a su vez pueden ser usados como un umbral para activar sistemas de humidificación que proporcionen una condición de crecimiento óptima, dependiendo de los objetivos de producción y las preferencias de los productores, orientándolos a una meta de calidad para consumo o procesamiento (Shamshiri, 2017).

Definir el comportamiento de la humedad mediante sistemas de inferencia difusa otorga un vínculo entre el nivel de complejidad, la experiencia humana y la pertinencia del modelo requerido, el cual, si se reproduce fielmente, permite la toma de decisiones para el mejoramiento de control y regulación climática, teniendo en cuenta que su rendimiento depende de la naturaleza y la calidad de la información que se tenga del entorno (Heidari & Khodadadi, 2017). Asimismo el uso de controladores basados en sistemas de inferencia difusa para monitorear y controlar variables en un invernadero garantiza: eficiencia operativa, reducción del gasto energético y disminución significativa en la intervención humana, además de mejorar la productividad de los cultivos protegidos (Faouzi y col., 2017).

La optimización de los parámetros de los sistemas de inferencia difusa mediante el uso de diversos métodos como los algoritmos genéticos o el algoritmo PSO, ha introducido modelos más robustos, estables y que responden rápidamente a perturbaciones e incertidumbres de parámetros. Estas técnicas abordan las características de no linealidad que poseen las variables estudiadas y proporcionan un mejor rendimiento, comparado con modelos difusos tradicionales, definidos de forma empírica, reduciendo el daño de los cultivos y las pérdidas de producción (Koutb y col., 2004; Revathi & Sivakumaran, 2016).

Capítulo 5

MARCO DE REFERENCIA

5.1. MARCO CONCEPTUAL

En esta sección se abordaran la descripción y definición de los términos que van a emplearse en la investigación enmarcandose en el problema definido, entre los que se encuentran los sistemas de inferencia difusa, los métodos de optimización, las técnicas de medición del error para el caso de predicción y algunos casos exitosos de desarrollos de invernaderos orientados a la vida urbana y que son objeto de estudio.

5.1.1. Sistemas de inferencia difusa

Un sistema inferencia difusa consiste en un sistema en el cual los rangos de las variables sobre los cuales representan sus estados (o, al menos, algunas de ellas) se tratan de conjuntos difusos que son definidos en un intervalo de números reales y a su vez tanto los conjuntos como las variables se les asocia un significado lingüístico (Klir & Yuan, 1995; Ross, 2010). A continuación se realiza una descripción de los sistemas de inferencia difusa tipo MAMDANI, Sugeno y neorodifuso adaptativo (ANFIS) junto con algunas técnicas de agrupamiento difuso asociadas.

Sistema de inferencia difusa tipo MAMDANI

Los sistemas de inferencia difusa de tipo Mamdani fueron diseñados originalmente para imitar el rendimiento de los operarios humanos encargados de controlar ciertos procesos industriales pretendiendo resumir la experiencia del operario en una serie de reglas (lingüísticas) condicionales SI-ENTONCES (IF-THEN), que una máquina pueda emplear, para controlar automáticamente el proceso. Un sistema difuso de tipo Mamdani define una función f que genera salidas numéricas $y = f(x)$ a partir de valores

(por lo general numéricos) de entrada x utilizando un conjunto de reglas condicionales (Izquierdo & Izquierdo, 2018).

La mayoría de sistemas Mamdani están compuestos de múltiples reglas condicionales (IF-THEN) y cada una de estas puede pertenecer a distintos conjuntos difusos, además, los antecedentes y los consecuentes se conectan a través de conectores lógicos “Y” (AND) y “O” (OR) (Izquierdo & Izquierdo, 2018).

El sistema Mamdani pasa por seis etapas para calcular la respectiva salida, las cuales son (Knapp, 2007b):

- Determinar un conjunto de reglas difusas.
- Realizar el proceso de creación de los conjuntos difusos en las entradas utilizando las funciones de pertenencia de las mismas Fuzzificación.
- Combinar las entradas difusas de acuerdo a las reglas difusas para establecer el peso de la regla.
- Encontrar la consecuencia de la regla combinando el peso de la regla y la función de pertenencia de la salida.
- Combinar los consecuentes para obtener una distribución de salida.
- Realizar el proceso de Defuzzificación sobre la distribución de la salida cuando sea concreta.

Este proceso en sus seis etapas se observa en la Fig. 5.1, donde dada una entrada concreta se obtiene una salida (que puede ser difusa o concreta), detallando el flujo que involucra los componentes del sistema descritos en interfaz de fuzzificación y defuzzificación, base de conocimiento y unidad decisoria.

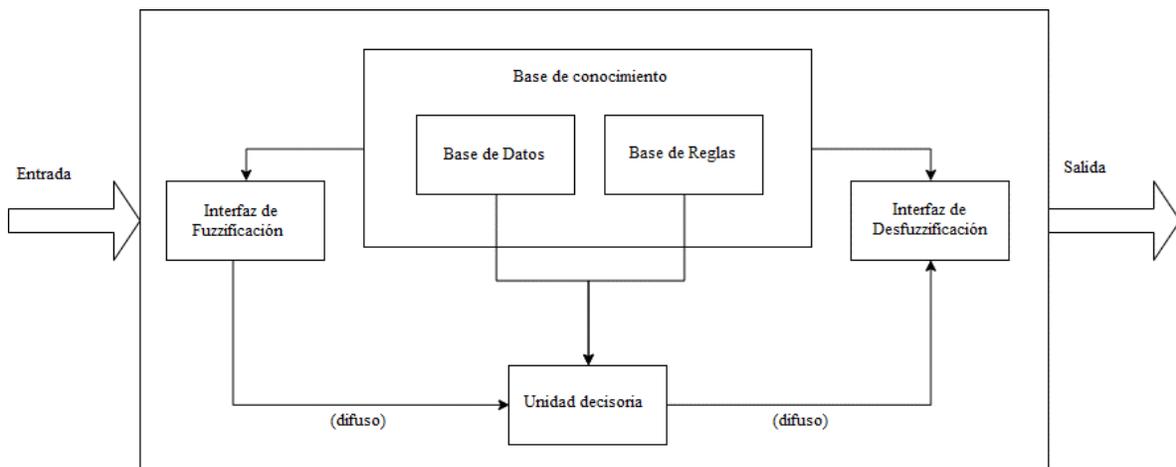


Fig. 5.1: Sistema de inferencia difusa convencional. Adaptado de (Mehran, 2008)

La Fig. 5.2, se muestra un sencillo ejemplo del proceso de inferencia en un sistema de tipo Mamdani para el otorgamiento de propinas de acuerdo al servicio proporcionado.

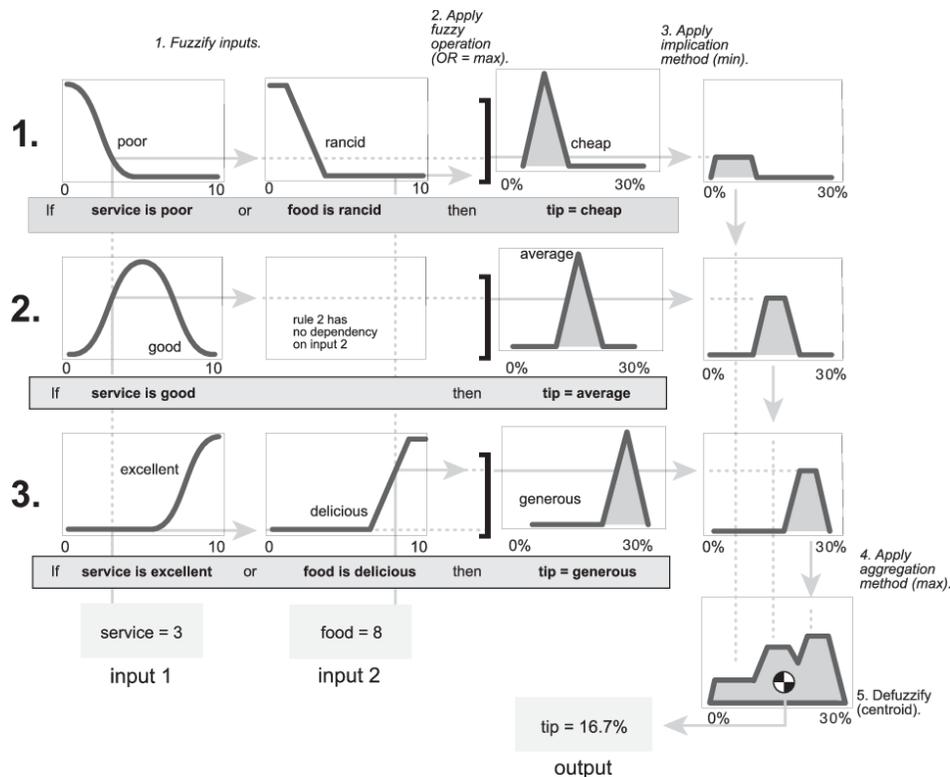


Fig. 5.2: Ejemplo de Inferencia en un sistema de inferencia difusa de tipo Mamdani. Tomado de (MathWorks Inc., 2019) © 2019 The MathWorks, Inc.

Entre las ventajas con las que cuenta un sistema de inferencia difusa de tipo Mamdani, se encuentran (MathWorks Inc., 2019):

- Es intuitivo.
- Esta diseñado para una apropiada entrada de datos para un ser humano.
- La base de reglas permite un alto grado de interpretabilidad.
- Posee amplia aceptación.

Sistema de inferencia difusa tipo SUGENO

De características similares al sistema de inferencia difusa tipo Mamdani, el sistema de inferencia difusa tipo Sugeno no posee una función de pertenencia en la salida, sino toma el valor de un número concreto que es calculado multiplicando cada entrada por una constante (coeficientes) y luego sumando los

resultados correspondientes (Knapp, 2007b). La característica principal de este modelo es que permite expresar la dinámica local de cada regla difusa mediante una expresión lineal (Mehran, 2008).

Entre las ventajas con las que cuenta un sistema de inferencia difusa de tipo Sugeno se pueden mencionar (MathWorks Inc., 2019):

- Se caracteriza por su eficiencia a nivel computacional.
- Funciona bien con técnicas de optimización y técnicas adaptativas.
- Funciona bien con técnicas lineales (ej: Control PID).
- Apropiada para realizar análisis matemático.

En la Fig. 5.3 se puede observar el esquema de un sistema de inferencia de tipo Sugeno para un sistema de dos entradas x e y .

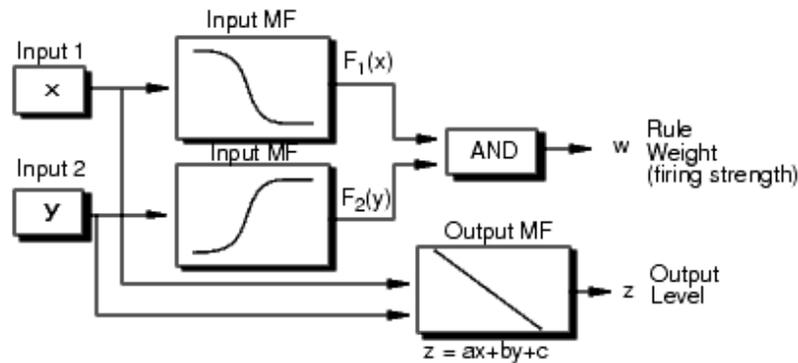


Fig. 5.3: Inferencia en un sistema de inferencia difusa de tipo Sugeno. Tomado de (MathWorks Inc., 2019) © 2019 The MathWorks, Inc.

Algunas características adicionales que posee este tipo de sistemas es que no hay un método intuitivo confiable para determinar los valores de los coeficientes y sólo cuenta con salidas concretas, un elemento poco interpretable para una aplicación de interacción humano-máquina (HCI) (Knapp, 2007b).

Sistema de inferencia neurodifusa adaptativo (ANFIS)

El sistema de inferencia neurodifuso adaptativo (ANFIS) consiste en un sistema de inferencia difusa que usa las redes neuronales adaptativas utilizando un procedimiento de aprendizaje híbrido. El ANIFS puede construir un mapa de entrada-salida basado tanto en conocimiento humano como de pares de entrada-salida estipulados. Entre sus aplicaciones se encuentra el modelo de funciones no lineales, predicción de series de tiempo caótica, aplicación en sistemas de control automático y procesamiento de señales (Shing & Jang, 1993).

En la Fig. 5.4 se puede observar un esquema basado en los sistemas de razonamiento difuso de tipo 1, junto a su equivalente en una arquitectura de tipo ANFIS (denominado ANFIS de tipo 1), donde se establece una relación entre las entradas del sistema de razonamiento difuso y sus salidas y se extrapolan en una arquitectura de tipo ANFIS.

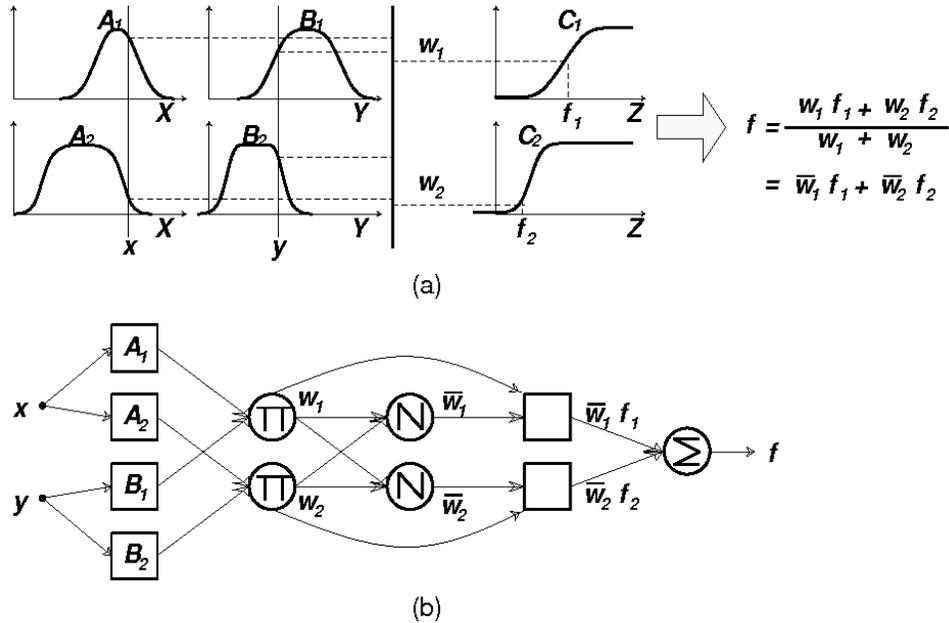


Fig. 5.4: Sistema de razonamiento difuso tipo 1 y su equivalente ANFIS de tipo 1. a) Razonamiento difuso de tipo 1. b) Equivalente ANFIS de tipo 1. Tomado de (Shing & Jang, 1993) © 1993 IEEE.

El desarrollo de los sistemas de inferencia neurodifuso adaptativos parte del hecho de optimizar los parámetros de un sistema de inferencia difuso a través de un algoritmo basado en las redes neuronales y el aprendizaje híbrido, donde se toma los parámetros del sistema de inferencia difuso y los adapta a los requeridos (Knapp, 2007a).

Los pasos que se deben realizar para construir un sistema ANFIS son (Knapp, 2007a):

- Diseñar un sistema de inferencia difusa de tipo Sugeno para realizar la clasificación.
- Optimizar manualmente el sistema de inferencia difusa dado los datos de clasificación de entrada.
- Preparar los datos de entrenamiento y de prueba. Estos datos están compuestos de entradas y la clasificación correspondiente a esas entradas.
- Ejecutar el algoritmo ANFIS en los datos de entrenamiento.
- Validar los resultados utilizando los datos de prueba.

Dentro de las ventajas que presenta un sistema ANFIS se encuentran su integración de representación de conocimiento bien estructurado y con otros métodos de diseño de control, y esto a su vez parte

de poseer una estructura matemática más específica, permitiéndoles ser un aproximador adaptativo. Frente a una implementación usando redes neuronales multicapa se presentan las siguientes ventajas (Isanta Navarro, s.f.):

- Mejor habilidad para el aprendizaje ya que se llega a una convergencia de error menor.
- No presenta una convergencia súbita precedida de una región de inestabilidad considerable.
- Requiere menor cantidad de parámetros ajustables.
- Su estructura permite el uso de la computación paralela.

Sistema de inferencia difusa de tipo Tsukamoto

En los sistemas de inferencia difusa de tipo Tsukamoto el consecuente de cada regla condicional está representado por un conjunto difuso con una función de pertenencia monótona. Esto significa que, las entradas de cada regla son concretas presentando un predicado y obteniendo como resultado final un promedio ponderado (Ariani & Endra, 2013). El valor hace referencia al valor mínimo del grado de pertenencia (Czabanski y col., 2017; Perangin-angin y col., 2016). Este modelo de inferencia es bastante útil en situaciones de vaguedad e incertidumbre, aportando tanto flexibilidad como tolerancia en el análisis de los datos (Adriyendi, 2018).

El funcionamiento del sistema de inferencia difuso Tsukamoto se divide en siete etapas, las cuales son (Adriyendi, 2018):

- Fuzzificación.
- Calculo a partir de la función de pertenencia.
- Inferencia.
- Obtención de la variable difusa.
- Composición.
- Obtención del valor de pertenencia.
- Defuzzificación.

En la Fig. 5.5 se evidencian las etapas que caracterizan el funcionamiento del sistema de inferencia Tsukamoto (Adriyendi, 2018):



Fig. 5.5: Funcionamiento del sistema de inferencia Tsukamoto. Adaptado de (Adriyendi, 2018).

Agrupamiento difuso

La agrupación de datos identifica agrupaciones naturales de datos de un gran conjunto de datos para producir una representación concisa del comportamiento de un sistema. La información del clúster puede ser usada para generar un sistema de inferencia difusa que modele mejor el comportamiento de los datos utilizando un número mínimo de reglas. Las reglas se dividen a sí mismas de acuerdo con las cualidades difusas asociadas con cada uno de los grupos de datos (MathWorks Inc., 2021c). Algunas de las implementaciones de agrupamiento difuso para la construcción de sistemas de inferencia difusa son (MathWorks Inc., 2021c, 2021d):

- Partición de cuadrícula (GridPartition): Genere funciones de pertenencia de entrada dividiendo uniformemente los rangos de variables de entrada y cree un sistema difuso Sugeno de salida única. La base de reglas difusas contiene una regla para cada combinación de función de pertenencia de entrada.
- Agrupación sustractiva (SubtractiveClustering): Genere un sistema difuso Sugeno usando funciones de pertenencia y reglas derivadas de grupos de datos encontrados usando agrupaciones sustractivas de datos de entrada y salida, es utilizado cuando no se conoce el número de grupos a formar.
- Agrupación difusa de C-medias (FCMClusterin): Genere un sistema difuso utilizando la función de pertenencia y las reglas derivadas de los grupos de datos que se encuentran utilizando el agrupamiento FCM de datos de entrada y salida. FCM comienza con una estimación inicial de los centros de los clusters, que están destinados a marcar la ubicación media de cada grupo,

después asigna a cada punto de datos un grado de membresía para cada clúster que al actualizar iterativamente los centros de los grupos y las calificaciones de membresía para cada punto de datos, mueve de manera iterativa los centros de los grupos a la ubicación correcta dentro de un conjunto de datos. Esta iteración se basa en minimizar una función objetivo que representa la distancia desde cualquier punto de datos dado a un centro de grupo ponderado por el grado de pertenencia de ese punto de datos.

5.1.2. Métodos de optimización

El objetivo de los métodos de optimización es encontrar una solución óptima o casi óptima con un bajo esfuerzo computacional, medido como el tiempo de cálculo y la memoria que consume el mismo (Rothlauf, 2011). En este apartado se reúne una descripción de los métodos de optimización más utilizados para cambiar los parámetros de los modelos de predicción de variables dinámicas como la humedad con el propósito de aumentar su grado de precisión, entre los que se encuentran los algoritmos genéticos, el algoritmo Cuasi-Newton y el algoritmo de punto interior.

Algoritmo genético

Los algoritmos genéticos son algoritmos basados en los principios de la genética y de la selección natural como lo son los conceptos de reproducción, cruzamiento y mutación usados para el procedimiento de búsqueda genética (Rao, 2009).

Los algoritmos genéticos se caracterizan por (Rao, 2009):

- Se utiliza el conjunto de valores resultado de la evaluación de la función objetivo como el total de soluciones posibles del problema, de donde se toma un conjunto de estos como población inicial. Si el número de variables en el diseño es n , el tamaño de la población se toma de $2n$ a $4n$.
- Debido a que muchos individuos de la población son utilizados como soluciones candidatas, este algoritmo no suele caer en un óptimo local.
- Las variables de diseño son representadas como individuos de la población que corresponden a cromosomas en la genética.
- La función objetivo corresponde a un vector de diseño que toma el rol de fitness o aptitud en la genética.
- En cada generación, un nuevo conjunto de individuos se produce utilizando algún tipo de selección y cruzamiento de las poblaciones o generaciones.
- Su funcionamiento se basa en la exploración eficiente de las nuevas combinaciones con el conocimiento disponible para hallar una nueva generación o población con mejor fitness.

Algunos tipos de implementaciones con características específicas de algoritmos genéticos se describen a continuación (Guo y col., 2010).

- Algoritmo genético híbrido (Hybrid genetic algorithm - HGA): Pretende encontrar los valores iniciales adecuados para el algoritmo genético, ya que la selección de los mismos, satisfaciendo el conjunto de restricciones establecidas, no está delimitada bajo una única metodología y diversos valores iniciales influyen en los resultados del algoritmo. El HGA aplica un algoritmo genético para proveer un conjunto inicial de variables de diseño y así evitar el proceso de prueba; posteriormente, se aplica un algoritmo de optimización tradicional para hallar el resultado óptimo.
- Algoritmo genético de intervalo (Interval genetic algorithm - IGA): Permite obtener los parámetros optimizados y excluir del proceso de optimización el análisis de intervalo, en la optimización de intervalos donde se establece las cotas superiores e inferiores en el efecto de todos los errores en una cantidad computada, permitiendo comprender la relación entre los parámetros del sistema y su rendimiento.
- Algoritmo genético híbrido de intervalo (Hybrid interval genetic algorithm - HIGA): Combina IGA con software de método de elementos finitos para la optimización de intervalos permitiendo determinar soluciones precisas sin la necesidad de formular un sistema de ecuaciones complejo.

Algoritmo Cuasi-Newton

Algoritmo iterativo basado en el método de la secante, que conlleva una serie de búsquedas lineales y al cálculo del valor de una función f junto con su gradiente en cada iteración reutilizando la información de las iteraciones previas (Bryan, 2017). Este algoritmo soluciona el problema del coste computacional en el que incurre el método de Newton para resolver sistemas de ecuaciones no lineales, ya que el cálculo de derivadas parciales en un punto y su solución a través de la matriz jacobiana correspondiente presenta un alto coste a nivel computacional (Lambers, 2011b). Adicionalmente aprovecha las ventajas del método de Newton como su rápida convergencia, y su funcionamiento como un método descendiente que busca un óptimo en vez de puntos críticos generales (Bryan, 2017).

Algunas implementaciones de algoritmo Cuasi-Newton específicas son:

- Método de Broyden: Teniendo en cuenta el cálculo de la matriz jacobiana que requiere n^2 derivadas parciales y una evaluación de $2n^2$ veces, este método se aprovecha de la propiedad de la matriz jacobiana que se presenta en (5.1) (Lambers, 2011a; Mathews, 2005):

$$J(\vec{X})\Delta\vec{X} \approx \Delta\vec{F}(\vec{X}) \quad (5.1)$$

Con ello se puede reescribir la ecuación

$$J(\vec{P}_k)(\vec{P}_k - \vec{P}_{k-1}) = \vec{F}(\vec{P}_k) - \vec{F}(\vec{P}_{k-1}) \quad (5.2)$$

El método parte de la matriz jacobiana $A_0 = J(\vec{P}_0)$ y luego en iteraciones sucesivas se utiliza una actualización de la matriz jacobiana aproximada con la matriz A_k .

$$A_k(\vec{P}_k - P_{k-1}) = \vec{F}(\vec{P}_k) - \vec{F}(P_{k-1}), k = 1, 2, \dots \quad (5.3)$$

Así se llega a la solución mediante la expresión (5.3) conocida como la condición de la secante o cuasi newtoniana. Se debe considerar que se requieren dos valores o puntos iniciales \vec{P}_0 y \vec{P}_1 para iniciar el método de la secante, no obstante, si se cuenta con solo un valor inicial se puede hallar \vec{P}_1 mediante el método de Newton.

- Método de Broyden-Fletcher-Goldfarb-Shanno (BFGS) Es uno de los métodos más populares y exitosos con un alto grado de usabilidad basado en la tasa de convergencia y en su característica iterativa, dependiendo en gran medida del problema (Auken y col., 2017). El algoritmo se describe mediante el siguiente pseudocódigo (Nocedal & Wright, 2006):

```

x0 Punto inicial
ε: Tolerancia
k ← 0;
while ||∇fk|| > ε
    while pk = -Hk∇fk;
        while xk+1 = xk + αkpk; αk
            sk = xk+1 - xk;
            yk = ∇fk+1 - ∇fk;
            Hk+1 = (I - pkskykT)Hk(I - pkskykT) + pkskykT; pk =  $\frac{1}{(y_k^T s_k)}$ 
            k ← k+1;
    end (while)

```

Algoritmo de punto interior

Es un algoritmo de optimización no lineal restringido que maneja problemas grandes y dispersos, así como pequeños problemas densos o de punto interior. Este algoritmo satisface los límites en todas las iteraciones y puede recuperarse de resultados NaNInf además de ser un algoritmo a gran escala (MathWorks Inc., 2021a).

Al ser un algoritmo a gran escala utiliza álgebra lineal que no necesita almacenar, ni operar en, matrices completas, sino lo realiza internamente mediante el almacenamiento de matrices dispersas, y mediante el uso de álgebra lineal dispersa, disminuyendo una cantidad significativa de memoria y tiempo de ejecución (MathWorks Inc., 2021a).

El algoritmo de punto interior puede combinarse con otras técnicas de optimización y aceptar una función *Hessian* como entrada, obteniendo una solución más rápida y precisa para un problema de minimización restringida (MathWorks Inc., 2021c).

El enfoque de punto interior para la minimización restringida es resolver una secuencia de problemas aproximados de minimización donde el problema original se describe en (5.10) (MathWorks Inc., 2021b).

$$\min_x f(x), \text{ sujeto a } h(x) = 0 \text{ y } g(x) \leq 0 \quad (5.4)$$

Donde por cada $\mu > 0$, el problema aproximado es (5.5).

$$\min_{x,s} f_\mu(x,s) = \min_{x,s} f(x) - \mu \sum_i \ln(s_i), \text{ sujeto a } s \geq 0, h(x) = 0, \text{ y } g(x) + s = 0 \quad (5.5)$$

Hay tantas variables de holgura s_i como restricciones de desigualdad g . Los s_i están restringidos a ser positivos para mantener los iterados en el interior de la región factible. A medida que μ disminuye a cero, el mínimo de f_μ debe acercarse al mínimo de f . El término logarítmico agregado se llama función de barrera.

5.1.3. Medición del error en la predicción

Permiten la evaluación del éxito de una predicción numérica mediante el establecimiento de diversas medidas. Los valores predichos en instancias de prueba se definen como $p_i, 0 \leq i \leq n$, mientras que los valores actuales como $a_i, 0 \leq i \leq n$. Algunas de las medidas más comunes para la evaluación del error son (Witten y col., 2017):

- Error cuadrático medio (Mean-Squared error - MSE): Es la medida principal y más común; generalmente se acompaña del uso de la raíz cuadrada para expresar el error en las mismas dimensiones que los valores predichos, conocido como RMSE. Permite medir el promedio de los cuadrados de los errores obteniendo siempre valores positivo como se describe en la (5.6), además es sensible a los datos atípicos y los valores más cercanos a cero representan un mayor grado de éxito en la predicción.

$$MSE = \frac{(p_1 - a_1)^2 + \dots + (p_n - a_n)^2}{n} \quad (5.6)$$

- Error absoluto medio (Mean-Absolute Error - MAE): Es una medida que promedia la magnitud de los errores individuales sin tener en cuenta el signo mediante la distancia horizontal promedio entre cada punto y la línea de identidad como se establece en (5.7). Los errores son tratados de acuerdo a su magnitud, por lo que no es muy sensible a los valores atípicos.

$$MAE = \frac{|p_1 - a_1| + \dots + |p_n - a_n|}{n} \quad (5.7)$$

- Error cuadrático relativo (Relative squared error - RSE): El error es construido relativo a lo que hubiera sucedido si un predictor simple o modelo trivial se hubiese aplicado como se ve en (5.8). Lo que hace este predictor es promediar los valores actuales de los datos de entrenamiento definidos como \vec{a} . Entonces el error cuadrático toma el error cuadrático total y lo normaliza dividiéndolo entre el error cuadrático total del predictor. Se usa la raíz cuando se quiere expresar

en las mismas dimensiones que los valores predichos.

$$RSE = \frac{(p_1 - \vec{p})^2 + \dots + (p_n - \vec{p})^2}{(a_1 - \vec{a})^2 + \dots + (a_n - \vec{a})^2} \quad (5.8)$$

- Error Relativo Absoluto (Relative Absolute Error - RAE): Se expresa como una razón, comparando un error medio con errores producidos por un predictor simple, es el error absoluto total dividido entre el error absoluto total del predictor que predice valores promedio. La fórmula se presenta en (5.9).

$$RAE = \frac{|p_1 - \vec{p}| + \dots + |p_n - \vec{p}|}{|a_1 - \vec{a}| + \dots + |a_n - \vec{a}|} \quad (5.9)$$

- Coeficiente de correlación (Correlation coefficient - ρ): Mide la correlación estadística entre el conjunto de datos de entrenamiento respecto a los datos de predicción. Toma valores entre -1 y 1, donde 0, presenta que no hay correlación entre los datos, y 1, correlación perfecta. No sufre afectación por la escala de los datos ni la existencia de dependencia entre las variables analizadas. La fórmula se presenta en (5.10).

$$\rho_{a,p} = \frac{\frac{\sum(p_i - \vec{p})(a_i - \vec{a})}{n-1}}{\sqrt{\frac{\sum(p_i - \vec{p})^2}{n-1} \frac{\sum(a_i - \vec{a})^2}{n-1}}} \quad (5.10)$$

5.2. MARCO TEÓRICO

En este apartado se muestran las investigaciones que conforman el estado del arte del problema analizado, comenzando por la recopilación de los modelos más relevantes para predicción de humedad en el clima y en un entorno de invernadero, y pasando finalmente a las propuestas que involucran sistemas de inferencia difusa.

5.2.1. Predicción de humedad climática

Los modelos de predicción que se muestran en la Tabla 5.1, reúnen un listado de los modelos predictivos de humedad más relevantes, estos muestran la relación de la humedad con otras variables climáticas y su comportamiento bajo fenómenos climáticos específicos como el del niño y de la niña, de la región ecuatorial de Sur América.

Tabla 5.1: Predicción de humedad climática. Elaboración Propia.

MODELOS DE PREDICCIÓN	AUTOR	DESCRIPCIÓN	VENTAJAS	DESVENTAJAS	IMPLEMENTACIÓN
Modelos de circulación general	(Ballabrera, 2010)	Son modelos del tipo matemático que se basan en ecuaciones de Navier-Stokes sobre una esfera rotatoria utilizando términos termodinámicos para las diversas fuentes de energía.	Pueden presentar todas las variables de la información espacial sobre las condiciones climáticas futuras. Pueden mantener la coherencia de la información interna.	La resolución espacial es relativamente baja. Pueden no presentar con precisión los parámetros climáticos.	Pronóstico del tiempo, comprensión del clima y proyección del cambio climático.

Tabla 5.1 Predicción de humedad climática. Elaboración Propia.

MODELOS DE PREDICCIÓN	AUTOR	DESCRIPCIÓN	VENTAJAS	DESVENTAJAS	IMPLEMENTACIÓN
Modelo Dinámico CFS	(Saha y col., 2010)	Representa la interacción global entre el océano, la tierra y la atmósfera, ofreciendo datos por hora con una resolución horizontal de hasta medio grado (hasta 56 Km) alrededor de la Tierra.	Maneja datos verídicos de los centros nacionales para la predicción ambiental y del sistema de asimilación de datos oceánicos globales.	Su principal desventaja es el trabajo con grillas grandes, por las cuales dejarían de tomar en cuenta fenómenos que ocurren a menor escala.	Modelos climáticos globales para análisis de los fenómenos del niño y la niña.

5.2.2. Predicción de humedad en invernaderos

Se muestra en la Tabla 5.2, un análisis comparativo que relaciona diversos tipos de modelos de predicción de humedad en invernaderos a través del tiempo, se describen su composición como implementación mostrando los resultados de validación del mismo. Se destacan los modelos con alto grado de precisión de (Fourati, 2014) y (Yue y col., 2018), resaltando que son propuestas basadas en redes neuronales y consiguen un buen modelamiento de las variables analizadas, con alto grado de precisión en su predicción.

Tabla 5.2: Predicción de humedad en invernaderos. Elaboración Propia.

MODELOS DE PREDICCIÓN	AUTOR	DESCRIPCIÓN	RESULTADOS DE VALIDACIÓN	IMPLEMENTACIÓN
Caracterización Palomo del Barrio	(Palomo Del Barrio, 1992)	Utiliza un diseño de sistemas de calefacción para analizar el efecto de las perturbaciones debido al aire y el calor.	Alto grado de coincidencia entre los valores medidos y estimados de la humedad con un modelo lineal para condiciones con alta transpiración.	En sistemas de calefacción y ventilación de invernaderos.
Modelo de Chaabane	(Baille y col., 1984)	Considera dentro de su análisis varios volúmenes de aire para modular su temperatura y humedad respecto a la temperatura del cultivo, la superficie del suelo y una malla térmica empleada.	No se comenta la validación del modelo.	Estudio de la influencia de una malla térmica sobre el clima nocturno.
Modelo de Cormary	(Rodríguez Díaz, 2005)	Modela la temperatura de la superficie interior y exterior de la cubierta del invernadero, junto a la temperatura y humedad del aire y la temperatura del cultivo y la superficie del suelo.	No presenta actuadores y tiene un vacío de 2°C en la temperatura del aire y 1°C en la del suelo.	Análisis en los aportes y efectos en cada proceso de los sistemas que actúan en un invernadero.

Tabla 5.2 Predicción de humedad en invernaderos. Elaboración Propia.

MODELOS DE PREDICCIÓN	AUTOR	DESCRIPCIÓN	RESULTADOS DE VALIDACIÓN	IMPLEMENTACIÓN
Modelo de Halleux	(Rodríguez Díaz, 2005)	Uso de ventilación natural y forzada junto a una malla térmica y Aero-termos para modular la humedad del aire y la temperatura de la cubierta interior y exterior y del cultivo y la superficie del suelo.	Durante un año de experiencias y en casos con/sin cultivo y con/sin calefacción, los errores medios menores de 2°C para temperatura y 5 % para humedad.	Análisis en el material de la cubierta. Análisis en la influencia del cultivo respecto al clima. Análisis de sistemas de calefacción.
Modelo basado en una red neuronal Elman y clasificadores ART2	(Fourati, 2014)	Se usa un clasificador ART2 junto con redes neuronales para modelar las variables de un invernadero como humedad, temperatura, radiación solar y velocidad del viento con el fin de aplicar técnicas de control basadas en redes neuronales.	La red neuronal Elman presento una computación más rápida debido a un menor numero de unidades y su capacidad de recordar estructuras de entrenamiento, adicionalmente en el control de las variables el error se redujo con la estrategia de control neuronal múltiple.	La información medioambiental almacenada es usada para modelamiento de condiciones ambientales de un invernadero para posterior aplicación de técnicas de control usando la división del proceso en períodos y ejecutando diversos actuadores a partir de las condiciones censadas.

Tabla 5.2 Predicción de humedad en invernaderos. Elaboración Propia.

MODELOS DE PREDICCIÓN	AUTOR	DESCRIPCIÓN	RESULTADOS DE VALIDACIÓN	IMPLEMENTACIÓN
Modelo de predicción basado en LM-RBF mejorado	(Yue y col., 2018)	Se prueban tres modelos de predicción utilizando los datos climáticos internos como entrada, así como la humedad y temperatura como salida. Los modelos analizados son RBF, PSO-RBF y LM-RBF, obteniéndose este último como el de mejor rendimiento.	Se contrasta mediante resultados experimentales, dando como mejor resultado el uso de LM-RBF, resaltando la optimización de la red neuronal RBF. Con un RMSE de $9.99E-06$ y $9.91E-06$ para temperatura y humedad respectivamente.	Utilizado para pronosticar la temperatura y la humedad de un invernadero y guiar su control.

5.2.3. Predicción de humedad en invernaderos con sistemas de inferencia difusa

Se abordan diversas investigaciones que exploran múltiples implementaciones de sistemas de inferencia difusa que permiten predecir los valores de humedad en invernaderos, pero cuyo fin puede no limitarse a este, como se observa en la Tabla 5.3, encontrándose desarrollos relacionados con técnicas de control o fines académicos. Se observa que se presentan soluciones con gran precisión a costa de su característica de interpretabilidad como en las propuestas de (Boughamsa & Ramdani, 2018) y (Hurtado y col., 2010), o aumentan su grado de complejidad como en la implementación realizada por (Salgado & Cunha, 2005), pero que brinda gran modularidad a la solución.

Tabla 5.3: Modelos de predicción en invernaderos que involucran humedad usando sistemas de inferencia difusa. Elaboración Propia.

AUTOR	DESCRIPCIÓN	APLICACIÓN	VALIDACIÓN	SISTEMA DE INFERENCIA DIFUSA	MÉTODO DE OPTIMIZACIÓN	OBSERVACIÓN
(Boughamsa & Ramdani, 2018)	Describe un modelo de diseño de controlador predictivo para regular el microclima del invernadero, donde el ajuste de la temperatura y humedad internas son descritas por un modelo Takagi-Sugeno, cuyos valores son definidos por el algoritmo de clustering difuso C-means y optimizado por el algoritmo de mínimos cuadrados recursivos.	A partir del modelo de predicción, los actuadores del sistema de control permiten regular la temperatura y humedad interna mediante sistemas de calefacción y ventilación.	Los datos de entrada / salida se dividieron en dos 50 % para entrenamiento del modelo difuso y 50 % para validación. Obteniendo un RMSE y MAPE de 0.0001 y 0.2952 para humedad respectivamente. Se compara con un modelo ARX obteniendo mejores resultados.	Takagi-Sugeno (TS)	Algoritmo de mínimos cuadrados recursivos (RLS)	El uso de algoritmos de clustering difuso aumenta su grado de complejidad y tiene un bajo grado de interpretación en su salida.
(Heidari & Khodadadi, 2017)	Se identifica el modelo matemático de clima de invernadero y se mantienen la temperatura y la humedad en los rangos predeterminados mediante un controlador PID de autoajuste de lógica difusa.	A partir del modelo basado entre la relación de las entradas y las salidas se desarrolla un controlador PID de autoajuste de lógica difusa.	Se toman los valores de un invernadero construido a pequeña escala y se comparan los valores obtenidos mediante un controlador PID y un controlador PID de autoajuste de lógica difusa.	Mamdani	n/a	Su precisión no es tan alta, debido a que sus valores no son optimizados.
(Putti y col., 2017)	Se desarrolló un modelo matemático difuso para estimar los impactos del calentamiento global en la vitalidad de <i>Laelia purpurata</i> . Los resultados del modelo difuso podrían predecir con precisión las condiciones óptimas para el cultivo.	Estimar los impactos del calentamiento global en la vitalidad de <i>Laelia purpurata</i> que crece en varios sitios de Brasil.	Para desarrollar el modelo matemático se consideraron como factores intrínsecos los parámetros: temperatura, humedad y condiciones de sombra para determinar la vitalidad de las plantas.	Mamdani	n/a	Su precisión no es tan alta, debido a que sus valores no son optimizados

Tabla 5.3 Modelos de predicción en invernaderos que involucran humedad usando sistemas de inferencia difusa. Elaboración Propia.

AUTOR	DESCRIPCIÓN	APLICACIÓN	VALIDACIÓN	SISTEMA DE INFERENCIA DIFUSA	MÉTODO DE OPTIMIZACIÓN	OBSERVACIÓN
(Hurtado y col., 2010)	Se presenta el desarrollo e implementación de tres algoritmos de agrupamiento difuso: K-means, C-means y agrupamiento difuso sustractivo, para el diseño de sistemas difusos.	Se utiliza para el modelado de temperatura y humedad de un invernadero utilizado como laboratorio de biotrófica en la Universidad Autónoma de Querétaro.	Se comparan los datos semanales comparando los datos experimentales con las predicciones realizadas por el sistema difuso obtenido para cada técnica de agrupamiento utilizada.	Takagi-Sugeno-Khan (TSK)	n/a	El uso de algoritmos de clustering difuso aumenta su grado de complejidad y tiene un bajo grado de interpretación en su salida.
(Salgado & Cunha, 2005)	Se aplica una técnica de modelado difuso que organiza automáticamente los conjuntos de reglas difusas IF-THEN en una estructura colaborativa jerárquica, utilizando agrupamiento mediante el algoritmo de subgrafos altamente conectados (HCS).	Se probó para dividir los modelos difusos planos de temperatura y humedad del aire del invernadero en submodelos difusos, que tienen una contraparte similar en los submodelos físicos.	Se comparan los datos experimentales con los simulados mediante los sub-modelos difusos.	Sistema difuso colaborativo jerárquico	n/a	Su construcción jerárquica aumenta su grado de complejidad.
(Ramdani y col., 2015)	Aplicación del modelo difuso de control predictivo para regular el microclima de los procesos agrícolas. Los valores de las regiones son definidos por el algoritmo de agrupación de Gustafson-Kessel (G-K) usando el método de mínimos cuadrados ponderados (WLS) por separado para cada regla.	Se utiliza para el control y regulación de la temperatura y humedad dentro de un microclima de invernadero.	Los resultados de la simulación revelaron que el enfoque propuesto pudo mantener la temperatura y la humedad dentro del invernadero alrededor de los puntos de referencia deseados.	Takagi-Sugeno (TS)	n/a	El uso de algoritmos de clustering difuso aumenta su grado de complejidad y tiene un bajo grado de interpretación en su salida.

Tabla 5.3 Modelos de predicción en invernaderos que involucran humedad usando sistemas de inferencia difusa. Elaboración Propia.

AUTOR	DESCRIPCIÓN	APLICACIÓN	VALIDACIÓN	SISTEMA DE INFERENCIA DIFUSA	MÉTODO DE OPTIMIZACIÓN	OBSERVACIÓN
(Nachidi y col., 2006)	Se propone la construcción de un modelo difuso Takagi-Sugeno (T-S) a partir de un modelo dinámico no lineal simplificado del clima de invernadero.	El modelo obtenido es usado para el control de la temperatura del aire y la concentración de humedad en el invernadero.	Es posible controlar con éxito mediante el uso de modelos difusos T-S y el concepto de compensación distribuida en paralelo (PDC). Se presentan los resultados de la simulación de cinco pruebas que muestran el desempeño y estabilidad obtenidos.	Takagi-Sugeno (TS)	n/a	Tiene un bajo grado de interpretación en su salida y el uso de ecuaciones no lineales aumenta el grado de complejidad.
(Javadikia y col., 2009)	A partir de un modelo de invernadero con ecuaciones termodinámicas se diseñan dos controladores climáticos de invernadero uno difuso y otro On / Off.	El controlador difuso propuesto a partir del modelo termodinámico permite el control de la temperatura y humedad del invernadero.	Se compara el desempeño de ambos controladores obteniendo que el controlador difuso es fácil de usar, fácil de diseñar, altamente adaptable, rápido de realizar y con mayor rendimiento.	Mamdani	n/a	Su precisión no es tan alta, debido a que sus valores no son optimizados
(Algarín y col., 2017)	Diseño e implementación de un sistema de bajo costo para monitoreo y control remoto de un invernadero mediante lógica difusa.	Se optimizó el uso de recursos para un prototipo de invernadero de techo a dos aguas mediante su monitoreo y control remoto.	Se verificó la eficacia de la lógica difusa para controlar sistemas no lineales sin el modelo matemático de la planta, tomando 10 minutos para estabilizar el valor de humedad en el rango esperado.	Mamdani	n/a	Su precisión no es tan alta, debido a que sus valores no son optimizados
(Maher y col., 2016)	Modelo físico de un invernadero, validado experimentalmente, con el fin de proponer un controlador de base difusa para gestionar el clima interior de un invernadero utilizando algunos actuadores.	Los valores RMSE de 3,16 % para humedad muestran una buena concordancia entre los datos calculados y medidos.	Los resultados de la simulación muestran la eficacia del controlador difuso y del generador fotovoltaico para ahorrar energía y reducir los costos de producción de cultivos en invernaderos.	Mamdani	n/a	Su precisión no es tan alta, debido a que sus valores no son optimizados

Tabla 5.3 Modelos de predicción en invernaderos que involucran humedad usando sistemas de inferencia difusa. Elaboración Propia.

AUTOR	DESCRIPCIÓN	APLICACIÓN	VALIDACIÓN	SISTEMA DE INFERENCIA DIFUSA	MÉTODO DE OPTIMIZACIÓN	OBSERVACIÓN
(Guerrero-Santana y col., 2018)	Se generaron ANFIS para pronosticar la humedad y temperatura dentro de un sistema de secado de invernadero solar (SGDS) durante el proceso de secado de hojas de Stevia.	La predicción es un punto de partida para aplicar técnicas de control adecuadas a los SDGS y ayudan al productor de Stevia a conocer de manera efectiva el comportamiento del sistema en condiciones climáticas similares.	Se desarrollaron y se evaluaron experimentalmente, mostrando buena concordancia entre el pronóstico del modelo y la medición de variables, proporcionando una buena estimación.	ANFIS	n/a	Tiene un bajo grado de interpretación en su salida.
(Ding y col., 2018)	Sistema de predicción y control de invernadero utilizando un controlador lógico programable (PLC) y un sistema de control de supervisión y adquisición de datos (SCADA).	Permite la predicción de los parámetros ambientales óptimos para el crecimiento de <i>Dendrobium candidum</i>	Se comparan los datos obteniendo un error de predicción promedio del modelo actual inferior al 2,5 %.	Takagi-Sugeno (TS)	Red neuronal de optimización difusa de tres capas feed-forward.	Se usa un método difuso para las acciones de control de los actuadores más no para la predicción, aumentando la complejidad y disminuyendo la interpretación.
(Jian-kun y col., 2014)	Modelo de ambiente de invernadero combinado con un controlador de ventilación basado en ANFIS que describe el comportamiento de humedad con diagrama de bloques de Simulink basado en ecuaciones de diferencias del equilibrio de humedad del aire.	Control difuso para el control inteligente del microclima del invernadero.	Se comparan los valores de las variables al ser controlados y su grado de oscilación en promedio.	ANFIS	n/a	Tiene un bajo grado de interpretación en su salida y el uso de ecuaciones no lineales aumenta el grado de complejidad.

Tabla 5.3 Modelos de predicción en invernaderos que involucran humedad usando sistemas de inferencia difusa. Elaboración Propia.

AUTOR	DESCRIPCIÓN	APLICACIÓN	VALIDACIÓN	SISTEMA DE INFERENCIA DIFUSA	MÉTODO DE OPTIMIZACIÓN	OBSERVACIÓN
(Morimoto & Hashimoto, 2000)	Modelo de control inteligente difuso con dos optimizadores que determinan respectivamente un punto de ajuste óptimo del entorno para el controlador difuso en función de las respuestas y ajustan el controlador difuso de manera óptima.	Controlar el medio ambiente de la fruta durante el almacenamiento en invernadero.	Comparación de la aptitud frente a diferentes números de división del proceso de control y mantener los valores de humedad en un patrón óptimo para la fruta.	Mamdani	Redes neuronales y algoritmos genéticos	Se usa para el almacenamiento de la fruta más no para el crecimiento de algún cultivo, presenta alta interpretabilidad y precisión.
(Lachouri y col., 2016)	Modelo del proceso de cultivo de las plantas de tomate en el interior del invernadero utilizando el sistema ANFIS para predecir el efecto de las variables meteorológicas y los actuadores de control.	Estimar con éxito el clima del invernadero durante el proceso de crecimiento de las plántulas de tomate.	Comparación y análisis de resultados entre el modelo experimental y ANFIS en función de los parámetros climáticos internos del invernadero.	ANFIS	Back-propagation y algoritmo de mínimos cuadrados	Tiene un bajo grado de interpretación en su salida pero un alto grado de precisión.
(Wang y col., 2020)	Sistema de control difuso adaptativo multimodelo de invernadero construido sobre un mecanismo de conmutación que puede considerar y manejar múltiples variables climáticas de invernadero.	Permite la gestión integral e inteligente del entorno de crecimiento de los cultivos.	El cambio de humedad relativa previsto se compara con la humedad relativa en el estado original.	Mamdani	n/a	Su precisión no es tan alta, debido a que sus valores no son optimizados.
(Trabelsi y col., 2007)	Modelo de descripción de temperatura y humedad basado en técnica de agrupamiento difuso para determinar tanto las premisas como los parámetros consiguientes de las reglas difusas de Takagi-Sugeno y posteriormente optimizando sus parámetros.	Modelar la temperatura y humedad del aire en el interior del invernadero para futuras acciones de control con base en el modelo.	Se usa una función VAF que calcula la varianza percentil contabilizada obteniendo la precisión de predicción del modelo difuso TS.	Takagi-Sugeno (TS)	Algoritmo recursivo de mínimos cuadrados ponderados (RWLS)	El uso de algoritmos de clustering difuso aumenta su grado de complejidad y tiene un bajo grado de interpretación en su salida.

Tabla 5.3 Modelos de predicción en invernaderos que involucran humedad usando sistemas de inferencia difusa. Elaboración Propia.

AUTOR	DESCRIPCIÓN	APLICACIÓN	VALIDACIÓN	SISTEMA DE INFERENCIA DIFUSA	MÉTODO DE OPTIMIZACIÓN	OBSERVACIÓN
(Hamza & Ramdani, 2020)	Se emplea un modelo difuso de intervalo de tipo 2 (IT2) Takagi-Sugeno para representar la dinámica no lineal de la planta sujeta a incertidumbres de los parámetros, que son capturadas de manera efectiva por las funciones de pertenencia de intervalo.	Control predictivo de modelo difuso en tiempo discreto de un invernadero.	El control predictivo del modelo difuso IT2 propuesto se comparó con el control predictivo del modelo difuso T1 en un microclima de invernadero mediante experimentos de simulación con MSE de 0.0120 y 0.0519 para simulaciones con incertidumbres de medición y de parámetros respectivamente.	Intervalo de tipo 2 Takagi-Sugeno (TS)	Desigualdad de matriz lineal (LMI)	Tiene un bajo grado de interpretación en su salida, pero un alto grado de precisión y el uso de variables de estado aumenta el grado de complejidad.
(Errahmani y col., 2009)	Modelo de predicción temperatura y humedad interna donde algoritmo propuesto se basa en la descomposición de la relación difusa en subrelaciones, a través de un proceso de desarrollo de las reglas difusas con cluster c-means.	Modelado de procesos físicos y biológicos dentro del invernadero.	Se comparan los resultados obtenidos de una simulación durante un período de prueba.	Takagi-Sugeno (TS)	n/a	El uso de algoritmos de clustering difuso aumenta su grado de complejidad y tiene un bajo grado de interpretación en su salida.
(Qiuying y col., 2010)	ANFIS para modelar el clima de invernadero en sus valores de temperatura interna, higrometría interna y radiación interna.	Modelado y simulación de ambientes de invernadero.	Los datos del sistema climático de invernadero se utilizan para entrenar y probar los modelos ANFIS evaluados mediante parámetros estadísticos como R2 y RMSE.	ANFIS	n/a	Tiene un bajo grado de interpretación en su salida pero un alto grado de precisión.

Tabla 5.3 Modelos de predicción en invernaderos que involucran humedad usando sistemas de inferencia difusa. Elaboración Propia.

AUTOR	DESCRIPCIÓN	APLICACIÓN	VALIDACIÓN	SISTEMA DE INFERENCIA DIFUSA	MÉTODO DE OPTIMIZACIÓN	OBSERVACIÓN
(Hamidane y col., 2021)	Modelo de predicción y temperatura interna mediante conjuntos difusos de tipo ANFIS.	Modelado y simulación de temperatura y humedad de invernadero.	Se comparan los resultados observados con los del modelo mediante MSE, RMSE y R2 en las fases de entrenamiento y prueba, obteniéndose en humedad un RMSE de 0.6336 y un R2 0.8862.	ANFIS	n/a	La precisión en humedad no fue tan satisfactoria, y tiene un bajo grado de interpretación en su salida.

5.2.4. Funciones de pertenencia que describen humedad relativa en conjuntos difusos

A partir de los modelos de predicción en invernaderos que usan sistemas de inferencia difusa e involucran humedad se realiza una recopilación de las funciones de pertenencia que describen los valores de humedad relativa en cada uno de los conjuntos difusos, como se muestra en la Tabla 5.4, relacionando la investigación junto con la función de pertenencia usada y el método de obtención que se realizó para determinar la misma. A partir de este análisis se determinó que las funciones de pertenencia más comunes son las triangulares, seguidas por las trapezoidales y gaussianas, con la definición de 3 a 5 rangos de valores para la humedad relativa.

Tabla 5.4: Funciones de pertenencia usadas para describir humedad relativa. Elaboración Propia.

AUTOR	MÉTODO DE OBTENCIÓN	FUNCIÓN DE MEMBRESÍA
(Boughamsa & Ramdani, 2018)	Los parámetros de la premisa se obtienen utilizando el algoritmo difuso de agrupación en clústeres C-Means (FCM).	Definidas por clúster difuso C-Means.
(Putti y col., 2017)	Con base en los datos de la revisión bibliográfica y la entrevista con un experto en cultivo de orquídeas.	Trapezoidal (trapmf) para bajo, medio y alto.

Tabla 5.4 Funciones de pertenencia usadas para describir humedad relativa. Elaboración Propia.

AUTOR	MÉTODO DE OBTENCIÓN	FUNCIÓN DE MEMBRESÍA
(Salgado & Cunha, 2005)	Mediante el modelo físico del comportamiento de las variables.	Triangulares (trimf) ajustadas por el algoritmo de agrupamiento (HCS). Trapezoidales a los extremos.
(Algarín y col., 2017)	Dependiendo de los valores óptimos, mínimos y máximos esperados para un determinado cultivo.	Triangulares para Mínimo Biológico, Óptimo, Máximo Biológico y trapezoidales a los extremos para Mínimo Letal y Máximo Letal.
(Guerrero-Santana y col., 2018)	Entradas como valores censados, salida ANFIS.	Definidas por clúster sustractivo.
(Lachouri y col., 2016)	Basada en la interacción de las variables del invernadero y los actuadores.	Tres funciones trapezoidales.
(Trabelsi y col., 2007)	Basado en la identificación a partir de cluster difuso.	Funciones gaussianas (gaussmf) definidas por cluster difuso.
(Taylan, 2017)	Basado en el modelo físico del entorno climático.	Funciones gaussianas para seco, promedio, húmedo, alto y muy alto.
(Mostakim y col., 2020)	Análisis modelo matemático y diseño a partir de bloques en Simulink.	Triangulares para muy bajo, bajo, normal, alto y muy alto.
(Prakash y col., 2015)	La función de membresía es seleccionada a partir de la prueba de diferentes funciones.	Tres funciones triangulares.
(Lanfang y col., 2000)	Mediante análisis del modelo físico.	Funciones gaussianas definidas por clúster difuso.
(Errahmani y col., 2009)	Estos modelos locales corresponden a las diferentes reglas generadas automáticamente que tienen parámetros lineales consecuentes variables.	Funciones gaussianas definidas por clúster difuso.

Tabla 5.4 Funciones de pertenencia usadas para describir humedad relativa. Elaboración Propia.

AUTOR	MÉTODO DE OBTENCIÓN	FUNCIÓN DE MEMBRESÍA
(Ameen & Al-Ameri, 2019)	Basado en el comportamiento de los actuadores.	Funciones triangulares para muy bajo, bajo, medio, alto y muy alto.
(Qiuying y col., 2010)	Tomado de los datos sensados del invernadero.	Definidas por clúster sustractivo. Se usan diferentes funciones de membresía como en forma de PI (pimf), trimf, gbellmf, gaussmf y gauss2mf y se comparan sus rendimientos.
(Nehra y col., 2015)	La función de membresía en forma de campana generalizada (gbellmf) se desarrolla para rosas de invernadero.	Campana generalizada (gbellmf) para baja, media y alta.
(Hamidane y col., 2021)	Basado en los datos y el modelo de interacción del invernadero.	Definidas por optimización híbrida mediante back-propagation con dos funciones de tipo partición de cuadrícula (Grid partition).

Capítulo 6

HIPÓTESIS

Un modelo basado en sistemas de inferencia difusa de tipo Mandani, donde las entradas son las variables que representan el balance térmico interno y la acción generada por los sistemas de calefacción, ventilación y riego, optimizado mediante una combinación de algoritmo genético y algoritmo de punto interior, permite determinar y pronosticar valores históricos y futuros de humedad relativa con alta interpretabilidad y precisión, logrando así el seguimiento y control durante el ciclo de desarrollo de los cultivos.

Capítulo 7

MARCO METODOLÓGICO

La técnica metodológica que se establece para el desarrollo del proyecto, se describe de manera gráfica en la Fig. 7.1. Esta dividida en 4 fases principales e interactúa en dos de sus fases con el modelo de proceso evolutivo basado en prototipos para el desarrollo de los componentes de software.

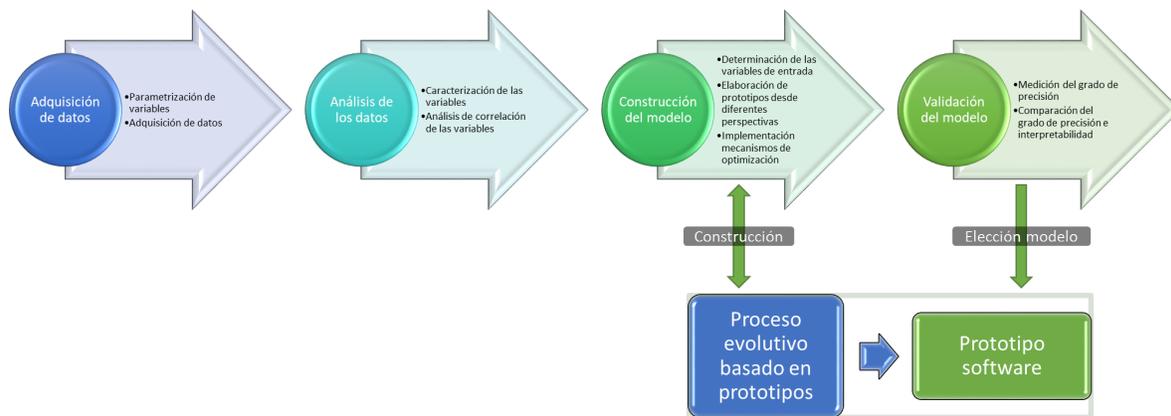


Fig. 7.1: Técnica metodológica aplicada. Adaptado de (Ding y col., 2018; Guerrero-Santana y col., 2018; Maher y col., 2016; Sampieri y col., 2014)

7.1. ADQUISICIÓN DE DATOS

Fase que agrupa todos los procesos que se deben desarrollar para la obtención de los datos que serán el insumo principal para el modelo predictivo de humedad. Dentro de estos procesos se requiere una parametrización inicial de los sensores y actuadores del ambiente de invernadero para pasar al proceso de adquisición de datos.

7.1.1. Parametrización de variables

Teniendo en cuenta un ambiente gestionado por un microcontrolador, el cual contiene un conjunto de sensores y actuadores para su funcionamiento, se debe definir un cultivo para analizar y una ubicación geográfica donde se realiza el experimento (Baron y col., 2020). En este caso se configura el entorno de invernadero para un cultivo de habichuela en la ciudad de Bogotá-Colombia.

7.1.2. Adquisición de datos

Previa configuración de un invernadero experimental, se recopilan los datos correspondientes a las mediciones registradas en el invernadero experimental en un periodo de tres meses, estas mediciones se realizan cada minuto para cada una de las variables. Dentro de las variables de medición se encuentran:

- Humedad relativa interna.
- Temperatura interna.
- Humedad del suelo.
- Intensidad de luz.
- Concentración de CO₂.
- Luminosidad.
- Activación de ventilación.
- Activación del sistema de riego.
- Activación del sistema de calefacción.

7.2. ANÁLISIS DE LOS DATOS

A partir de los datos obtenidos previamente en el ambiente de invernadero se procede a realizar un análisis estadístico de los mismos, definiendo su comportamiento y las posibles dependencias entre las variables analizadas.

7.2.1. Caracterización de las variables

Utilizando estadística exploratoria se realiza un análisis de ocurrencia, tendencia, variabilidad, localización, simetría, forma y atípidad de los datos obtenidos por variable. Esto permite una caracterización más detallada de las variables que definen los elementos que conforman los conjuntos difusos que son usados en cada uno de los modelos.

7.2.2. Análisis de correlación de las variables

Se realiza un análisis estadístico multivariado para cada una de las variables, mediante dos coeficientes de correlación de Pearson y Spearman, y se realiza una identificación de las dependencias y su relación con la humedad relativa interna.

7.3. CONSTRUCCIÓN DEL MODELO

Se realiza mediante un ciclo iterativo incremental, donde se determinan y prueban cada uno de los parámetros que conforman los sistemas de inferencia difusa a utilizar y los algoritmos de optimización que se usan para aumentar su rendimiento, con el objeto de hallar la más alta precisión en cada una de las propuestas con una determinada configuración. Del conjunto total de datos se toma el 70 % para el entrenamiento del modelo.

7.3.1. Determinación de las variables de entrada

Para la construcción del modelo se definen las variables de entrada que conforman cada una de las entradas de los sistemas de inferencia difusa y que presentaron en el análisis de correlación un efecto en la predicción de la humedad relativa interna del invernadero.

7.3.2. Elaboración de prototipos desde diferentes perspectivas

Teniendo en cuenta la elaboración de diferentes propuestas que se adaptan al crecimiento y al cambio se sigue un modelo de proceso evolutivo basado en prototipos. Las propuestas se desarrollan con base en los siguientes sistemas de inferencia difusa: Takagi-Sugeno (TS), Mamdani y ANFIS.

Para cada una de las configuraciones de los sistemas de inferencia difusa se prueba su rendimiento con el uso de algoritmos de agrupamiento difuso C-means. Por otra parte se generan dos propuestas por cada sistema de inferencia difusa para la predicción de los valores de humedad, teniendo en cuenta los datos disponibles en el entorno de invernadero, la primera parte del hecho de que la humedad relativa interna puede ser predicha con alto grado de precisión e interpretabilidad con la humedad relativa interna histórica y la segunda usa las variables que presentan correlación con la humedad.

7.3.3. Implementación mecanismos de optimización

A cada una de las propuestas de sistemas de inferencia difusa desarrolladas se les aplica una combinación de técnicas de optimización en método híbrido para mejorar su rendimiento en el siguiente orden:

1. Algoritmo Genético (GA).
2. Algoritmo de punto interior.

Esto con el objeto de partir de la búsqueda de una solución global, mediante una técnica heurística y optimizar su resultado mediante el uso de una técnica exacta que converja a la solución más cercana.

7.4. VALIDACIÓN DEL MODELO

Cada una de las propuestas de sistemas de inferencia difusa desarrolladas son validadas con el 30 % del conjunto total de datos que no se usaron para el entrenamiento.

7.4.1. Medición del grado de precisión

Para cada una de las propuestas de sistema de inferencia difusa desarrolladas se aplican medidas como el MSE, MAE y el RMSE, comparando los datos reales con los predichos.

7.4.2. Comparación del grado de precisión e interpretabilidad

Teniendo en cuenta el más alto grado de precisión e interpretabilidad de cada una de las propuestas, se realiza un comparativo de cada una, seleccionando así la propuesta que conforma el modelo predictivo de humedad en invernaderos para ser finalmente implementada en un prototipo software, siguiendo un proceso evolutivo basado en prototipos, desarrollado a partir del modelo aquí establecido.

7.5. MODELO DE PROCESO EVOLUTIVO BASADO EN PROTOTIPOS

Este modelo de proceso se soporta en el desarrollo de prototipos de software de manera iterativa e incremental de soluciones de software en los casos que el desarrollador no esta seguro de la eficiencia de un algoritmo (Pressman, 2019). El proceso esta conformado por 5 etapas, como se indica en la Fig. 7.2, comunicación, plan rápido, modelado y diseño rápido, construcción y despliegue, entrega y retroalimentación.

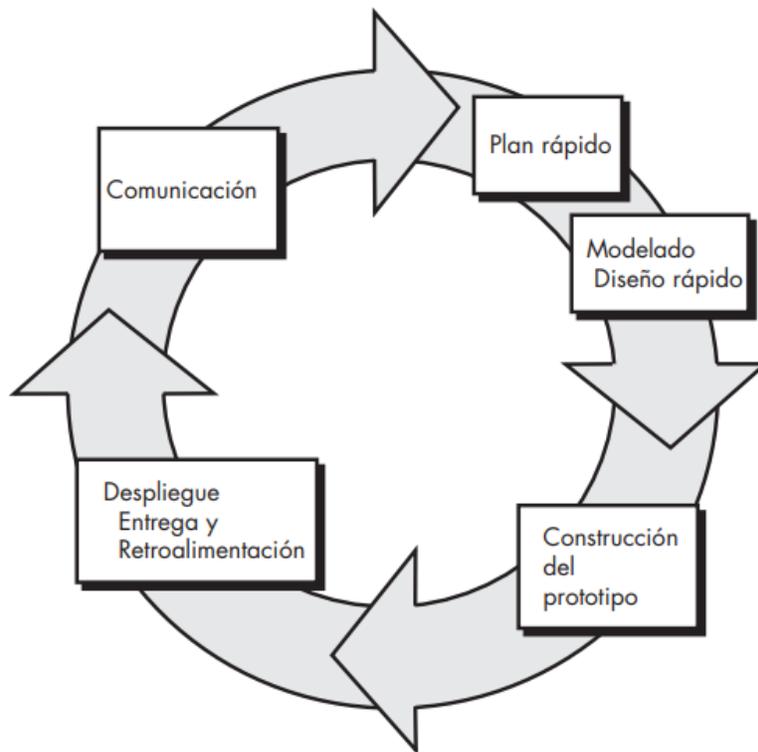


Fig. 7.2: El modelo de proceso para la creación de prototipos. Tomado de (Pressman, 2019)

El proceso evolutivo genera prototipos de manera iterativa e incremental, donde cada iteración ocurre a medida de que el prototipo es afinado para satisfacer las necesidades e incrementa el entendimiento de lo que se requiere hacer, esto se realiza siguiendo las siguientes fases (Pressman, 2019):

- **Comunicación:** Se definen los objetivos generales de la solución de software, identificando los requerimientos conocidos y donde se requiere mayor definición.
- **Plan rápido:** Se realiza un plan rápido de la iteración para hacer un prototipo que cumpla con las necesidades establecidas.
- **Modelado:** Se lleva a cabo un modelado en forma de diseño rápido que muestre tanto el diseño de los componentes, así como de las interfaces de interacción con los diversos usuarios.
- **Construcción del prototipo:** Se procede al desarrollo del prototipo software cumpliendo los requerimientos solicitados y obteniendo un producto funcional.
- **Entrega y retroalimentación:** El prototipo construido se entrega y es evaluado, donde se genera una retroalimentación que será implementada en la siguiente iteración, es decir el prototipo definido es la base para definir los requerimientos a adicionar.

Capítulo 8

LIMITACIONES

El registro del valor de las variables del ambiente de invernadero se encuentra restringido a los valores obtenidos en condiciones climatológicas de la ciudad de Bogotá D.C. y limitados a los sensores utilizados, donde para cada una de las variables se establecen los siguientes rangos:

- Humedad relativa interna: 0 a 100 %
- Temperatura interna: -40°C a 80 °C
- Humedad del suelo: 1 a 1023 V transformado a 0 a 100 %
- Intensidad de luz: ($\lambda 0,5$) 350nm a 375nm
- Concentración de CO₂: 300 a 10000ppm
- Luminosidad: 188 a 88000 Lux

Capítulo 9

DESARROLLO DE LA INVESTIGACIÓN

9.1. ADQUISICIÓN Y PREPROCESAMIENTO DE DATOS

Se muestran los resultados de la fase de adquisición de datos a partir de la implementación del entorno de invernadero y el posterior preprocesamiento de los mismos para facilitar su manejo y descripción mediante herramientas computacionales.

9.1.1. Adquisición de datos

A partir de un entorno de invernadero gestionado por un microcontrolador en la ciudad de Bogotá-Colombia a una altitud de 2559 metros, se recopilan tres conjuntos de datos entre los meses de junio y septiembre pertenecientes a: un prototipo de invernadero donde se cultivan habichuelas, otro prototipo de invernadero con las mismas características físicas donde se sensan las variables sin algún tipo de cultivo y un ultimo conjunto con el registro de los actuadores de ambos entornos controlados.

El entorno de invernadero donde se cultivan las habichuelas se registran un total de 98042 entradas (Vanegas, 2021b), para el segundo entorno un total de 115779 (Vanegas, 2021c) y para los actuadores de ambos entornos un total de 153926 entradas (Vanegas, 2021a). Los datos son descargados en formato CSV en cada repositorio y se procede al preprocesamiento de los mismos.

9.1.2. Preprocesamiento de datos

Para el procesamiento de los datos se plantea diferentes acciones que deben ser aplicadas a los datos para facilitar su manejo y descripción, estas son implementadas en el software Orange ©:

- Eliminación de los segundos en las fechas de registro para facilitar una unificación de los datos.
- Selección de las variables de estudio:
 - Humedad relativa interna (*hum*).
 - Temperatura interna (*temp*).
 - Humedad del suelo (*ground_humidity_per*).
 - Intensidad de luz (*light_Intensity*).
 - Concentración de CO_2 (*co2_ppm*).
 - Luminosidad (*luminosity*).
 - Activación de ventilación (*act_fan*).
 - Activación del sistema de riego (*act_solenoid_valve*).
 - Activación del sistema de calefacción (*act_heating*).
- Combinación de los datos de los actuadores con los datos sensados en un único conjunto de datos.
- Eliminación de los registros con información faltante.
- Normalización en el intervalo de $[0, 1]$.

Después del proceso de preprocesamiento de los datos, se obtiene un total de 61925 registros para el invernadero con cultivos de habichuela y de 80388 registros para el invernadero sin algún tipo de cultivo.

9.2. ANÁLISIS DE LOS DATOS

Con los conjuntos de datos obtenidos se realiza un análisis estadístico y de correlación de los mismos a través del software estadístico RStudio ©.

9.2.1. Estadística exploratoria de los datos

Para el conjunto de datos del invernadero con cultivos de habichuela se presentan los datos estadísticos de las variables en la Tabla 9.1, donde por cada variable se obtiene su promedio, desviación estándar, Coeficiente de Asimetría, Curtosis y los cuantiles 0, 0,25, 0,5, 0,75 y 1.

Tabla 9.1: Análisis exploratorio de las variables en invernadero con cultivos de habichuelas. Elaboración Propia.

x	\bar{x}	σ	ASIMETRÍA	CURTOSIS	0 %	25 %	50 %	75 %	100 %
act_fan	0.15253936	0.35954581	1.9328377	1.73591780	0	0.00000000	0.00000000	0.00000000	1
act_heating	0.11383125	0.31760876	2.4318046	3.91380017	0	0.00000000	0.00000000	0.00000000	1
act_solenoid_valve	0.03355672	0.18008662	5.1803775	24.83711288	0	0.00000000	0.00000000	0.00000000	1
co2_ppm	0.09974095	0.08708806	3.5546924	19.58887848	0	0.05239229	0.08400087	0.1121455	1
ground_humidity_per	0.62709550	0.21353123	-0.6608821	-0.33038421	0	0.50000000	0.70370370	0.8148148	1
hum	0.87382599	0.15438635	-1.3320890	1.50554501	0	0.78802395	0.94011976	1.00000000	1
light_Intensity	0.24009555	0.18741405	1.1521273	0.02054868	0	0.12153734	0.12153734	0.4061441	1
luminosity	0.18616786	0.22691410	1.3011977	0.62474161	0	0.02197373	0.05108137	0.3270054	1
temp	0.33717349	0.16374756	0.1102891	-0.76813738	0	0.18143460	0.37552743	0.4556962	1

En la Tabla 9.1 se observa una curtosis positiva en la mayoría de los casos a excepción de la humedad del suelo y la temperatura, adicionalmente se presenta un coeficiente de asimetría negativo para humedad relativa y humedad del suelo mostrando una concentración de los datos a la izquierda y en los otros casos positiva y por ende una concentración a la derecha, solamente siendo cercana a cero en el caso de la temperatura. Por otra parte para el conjunto de datos del invernadero sin ningún tipo de cultivo se presentan los datos estadísticos de las variables en la Tabla 9.2, que al igual que la tabla anterior se obtiene su promedio, desviación estándar, coeficiente de asimetría, curtosis y los cuantiles 0, 0,25, 0,5, 0,75 y 1.

Tabla 9.2: Análisis exploratorio de las variables en invernadero sin cultivos. Elaboración Propia.

x	\bar{x}	σ	ASIMETRÍA	CURTOSIS	0 %	25 %	50 %	75 %	100 %
act_fan	0.00000000	0.00000000	NaN	NaN	0	0.0000000000	0.00000000	0.00000000	0
act_heating	0.00000000	0.00000000	NaN	NaN	0	0.0000000000	0.00000000	0.00000000	0
act_solenoid_valve	0.05818033	0.23408558	3.7749500	12.2505520	0	0.0000000000	0.00000000	0.00000000	1
co2_ppm	0.18203681	0.10212710	3.8365866	19.8808551	0	0.1495762712	0.16398305	0.1775424	1
ground_humidity_per	0.23283326	0.30923736	1.5579955	0.4557163	0	0.0857142857	0.08571429	0.10000000	1
hum	0.56023415	0.22696510	0.5248792	-0.5209539	0	0.3932584270	0.52487961	0.6853933	1
light_Intensity	0.58395191	0.02016444	8.9108400	141.6261210	0	0.5760282792	0.57744894	0.5863030	1
luminosity	0.17137293	0.23117724	1.2068739	0.3240806	0	0.0001109826	0.02556300	0.3288147	1
temp	0.33747574	0.19897260	0.6173397	-0.6685336	0	0.1666666667	0.28703704	0.4907407	1

Como se evidencia en la Tabla 9.2 solo dos variables presentan una curtosis negativa humedad relativa y temperatura, además en relación a la asimetría todas presentan asimetrías positivas es decir con concentración de datos a la derecha y dos siendo cercanas a cero para los casos de humedad y temperatura. Por ultimo al no presentar comportamientos de control en ventilación y calefacción, al no tener ningún cultivo en desarrollo y solo con acciones de control en el sistema de riego para mantener el terreno húmedo, se muestran promedios negativos para los dos primeros controles y por ende en las otras medidas estadísticas.

Al comparar los datos de humedad en ambas tablas se observa que en el invernadero con cultivo de habichuelas se presenta un promedio de 0,87, y con los datos concentrados a la izquierda, es decir humedades altas, esto relacionado al funcionamiento de los sistemas de control, en cambio para el invernadero sin cultivos se presenta un promedio de 0,56 y valores más uniformemente concentrados.

9.2.2. Análisis de correlación de las variables

Para ambos entornos controlados se realiza un análisis de correlación mediante dos coeficientes el Coeficiente de correlación de Pearson y el Coeficiente de correlación de Spearman, adicionalmente se realiza una comparación con la selección de atributos mediante el método RReliefF y finalmente se obtienen las variables que presentan mayor correlación con la humedad relativa interna.

En el caso del invernadero con cultivos de habichuela se muestra en la Tabla 9.3 los coeficientes de correlación de Pearson para las variables del entorno, donde se destaca con mayor correlación directa con la humedad interna: la temperatura, seguida por la luminosidad y posteriormente la actuación de los sistemas de ventilación y calefacción.

Tabla 9.3: Matriz de correlación de Pearson de las variables en invernadero con cultivo de habichuelas. Elaboración Propia.

x	act_fan	act_heating	act_solenoid_valve	co2_ppm	ground_humidity_per	hum	light_Intensity	luminosity	temp
act_fan	1.00000000	-0.07540934	0.01347366	-0.17868574	-0.12410698	-0.21217538	0.09218160	0.11594259	0.02782150
act_heating	-0.07540934	1.00000000	-0.01878705	0.18356773	0.06709825	-0.14311003	-0.11381810	-0.15496794	-0.07382823
act_solenoid_valve	0.01347366	-0.01878705	1.00000000	0.37373417	0.03742506	0.04720622	0.03139722	0.01466340	0.00180411
co2_ppm	-0.17868574	0.18356773	0.37373417	1.00000000	0.25897151	0.13343597	0.02448769	-0.05979410	-0.08797421
ground_humidity_per	-0.12410698	0.06709825	0.03742506	0.25897151	1.00000000	0.11478124	0.23005741	-0.02917292	0.24359085
hum	-0.21217538	-0.14311003	0.04720622	0.13343597	0.11478124	1.00000000	-0.05989885	-0.24525942	-0.59590567
light_Intensity	0.09218160	-0.11381810	0.03139721	0.02448769	0.23005741	-0.05989885	1.00000000	0.85024660	0.39008900
luminosity	0.11594259	-0.15496794	0.01466340	-0.05979410	-0.02917292	-0.24525942	0.85024660	1.00000000	0.44783511
temp	0.02782150	-0.07382823	0.00180411	-0.08797421	0.24359085	-0.59590567	0.39008901	0.44783511	1.00000000

En lo referente a la correlación de Spearman se muestra en la Tabla 9.4 los coeficientes de correlación de Spearman, que muestran en su mayoría el mismo orden de correlación directa entre la humedad y las variables del entorno controlado.

Tabla 9.4: Matriz de correlación de Spearman de las variables en invernadero con cultivo de habichuelas. Elaboración Propia.

<i>x</i>	act_fan	act_heating	act_solenoid_valve	co2_ppm	ground_humidity_per	hum	light_Intensity	luminosity	temp
act_fan	1.00000000	-0.07540934	0.01347366	-0.26115166	-0.12481159	-0.18992217	0.08432573	0.14018483	0.03778666
act_heating	-0.07540934	1.00000000	-0.01878705	0.22110130	0.08637679	-0.18094150	-0.13385743	-0.22864675	-0.06591335
act_solenoid_valve	0.01347366	-0.01878705	1.00000000	0.24435251	0.04405036	0.03954997	0.05033743	0.03416412	0.00492665
co2_ppm	-0.26115166	0.22110130	0.24435251	1.00000000	0.21657951	0.16378467	0.14719167	-0.04258548	-0.10110001
ground_humidity_per	-0.12481159	0.08637679	0.04405036	0.21657951	1.00000000	-0.05409471	0.24598665	0.01973072	0.24111334
hum	-0.18992217	-0.18094150	0.03954997	0.16378467	-0.05409471	1.00000000	-0.10582178	-0.21576712	-0.58432615
light_Intensity	0.08432573	-0.13385743	0.05033743	0.14719167	0.24598665	-0.10582178	1.00000000	0.83074908	0.39788852
luminosity	0.14018483	-0.22864675	0.03416412	-0.04258548	0.01973072	-0.21576712	0.83074908	1.00000000	0.44140201
temp	0.03778666	-0.06591335	0.00492665	-0.10110001	0.24111334	-0.58432615	0.39788852	0.44140201	1.00000000

Por otra parte en el caso del invernadero sin cultivos se muestra en la Tabla 9.5 los coeficientes de correlación de Pearson, donde el orden de correlación directa con la humedad interna esta definido por: humedad del suelo, temperatura, luminosidad, concentración de CO_2 , actuación del sistema de riego y finalmente intensidad de luz.

Tabla 9.5: Matriz de correlación de Pearson de las variables en invernadero sin cultivos. Elaboración Propia.

x	act_solenoid_valve_2	co2_ppm	ground_humidity_per	hum	light_Intensity	luminosity	temp
act_solenoid_valve_2	1.000000000	-0.01786077	0.01861058	0.069036733	-0.027862869	-0.005018333	-0.007636341
co2_ppm	-0.017860768	1.000000000	0.12950360	0.105433809	0.015963675	0.025459516	0.010783918
ground_humidity_per	0.018610582	0.12950360	1.000000000	0.687848176	0.218820055	-0.020574231	0.086326453
hum	0.069036733	0.10543381	0.68784818	1.000000000	0.002786747	-0.280367564	-0.504906831
light_Intensity	-0.027862869	0.01596368	0.21882005	0.002786747	1.000000000	0.517214069	0.312339667
luminosity	-0.005018333	0.02545952	-0.02057423	-0.280367564	0.517214069	1.000000000	0.652847057
temp	-0.007636341	0.01078392	0.08632645	-0.504906831	0.312339667	0.652847057	1.000000000

Para la correlación de Spearman en el invernadero sin cultivos se muestran los coeficientes en la Tabla 9.6, donde el orden de correlación cambia de la siguiente manera: temperatura, humedad del suelo, luminosidad, intensidad de luz, actuación del sistema de riego y concentración de CO_2 .

Tabla 9.6: Matriz de correlación de Spearman de las variables en invernadero sin cultivos. Elaboración Propia.

x	act_solenoid_valve_2	co2_ppm	ground_humidity_per	hum	light_Intensity	luminosity	temp
act_solenoid_valve_2	1.000000000	0.0569829817	0.04063321	0.046006508	-0.008067377	0.0030075025	-0.006508000
co2_ppm	0.056982982	1.0000000000	0.16773266	0.009897621	-0.047497085	0.0005817624	0.001448314
ground_humidity_per	0.040633215	0.1677326614	1.000000000	0.455225942	-0.062768580	-0.1087461860	0.015844562
hum	0.046006508	0.0098976205	0.45522594	1.000000000	-0.138518913	-0.3312760208	-0.538062610
light_Intensity	-0.008067377	-0.0474970847	-0.06276858	-0.138518913	1.000000000	0.7780012881	0.441400721
luminosity	0.003007502	0.0005817624	-0.10874619	-0.331276021	0.778001288	1.0000000000	0.641862064
temp	-0.006508000	0.0014483140	0.01584456	-0.538062610	0.441400721	0.6418620639	1.000000000

A partir del método de selección de atributos RReliefF, se obtiene que para la humedad en el caso del entorno de invernadero con cultivos de habichuelas la selección de atributos la realiza el algoritmo en el siguiente orden:

1. Temperatura.
2. Luminosidad.
3. Humedad del suelo.
4. Intensidad de luz.
5. Concentración de CO_2 .
6. Activación de ventilación.
7. Activación del sistema de riego.
8. Activación del sistema de calefacción.

Por otra parte para el invernadero sin cultivos la selección se realiza en el siguiente orden:

1. Temperatura.
2. Concentración de CO_2 .
3. Luminosidad.
4. Humedad del suelo.
5. Intensidad de luz.
6. Activación del sistema de riego.

A partir de los análisis anteriores se realiza la ponderación tanto de los coeficientes de correlaciones como la selección de atributos, determinando así que las variables que tienen mayor grado de afectación en los valores de humedad relativa interna dentro de los invernaderos son:

- Temperatura, que a su vez relaciona los valores de luminosidad e intensidad de luz.
- Concentración de CO_2 , que a su vez relaciona los actuadores.
- Humedad del suelo, que a su vez relaciona la actuación del sistema de riego.

9.3. CONSTRUCCIÓN DEL MODELO

Se implementan dos propuestas para la predicción de los valores de humedad relativa interna teniendo en cuenta los datos disponibles en el entorno de invernadero, la primera a partir de la predicción basada en valores históricos y la segunda usando las variables de temperatura, concentración de CO_2 y humedad del suelo. Para cada una de las propuestas se realiza la construcción de varios modelos usando diversos sistemas de inferencia difusa y un mecanismo de optimización híbrido que implementa algoritmos de optimización y el algoritmo de punto interior, además se compara con el uso de mecanismos de agrupamiento difuso en cada una de las configuraciones.

9.3.1. Configuración sistemas de inferencia difusa

Se implementan los tres tipos de sistemas de inferencia difusa más comunes: Mamdani, Sugeno y ANFIS, la configuración de cada uno de estos se detalla a continuación y se muestra las funciones de pertenencia y conjuntos difusos para las entradas y la salida, junto con las reglas usadas para cada una de las propuestas.

Sistemas de inferencia difusa tipo Mamdani

La configuración del sistema se implementa a partir de los parámetros que se indican en la Tabla 9.7, donde se relaciona el valor dado a cada uno. Estos parámetros son ingresados en las funciones de MATLAB **mamfis**, para las configuraciones sin agrupamiento difuso y **genfis**, para las configuraciones con agrupamiento.

Tabla 9.7: Parámetros sistema de inferencia difusa tipo Mamdani.
Elaboración Propia.

PARÁMETRO	VALOR
Método de operador difuso AND.	El mínimo de valores de entrada difusos.
Método de operador difuso OR.	El máximo de valores de entrada difusos
Método de defuzzificación para calcular valores de salida nítidos.	Centroide del área debajo del conjunto difuso de salida.
Método de implicación para calcular el conjunto difuso consecuente.	Truncar la función de pertenencia consecuente en el valor del resultado antecedente.
Método de agregación para combinar consecuentes de reglas.	Máximo de conjuntos difusos consecuentes.

Sistemas de inferencia difusa tipo Sugeno

La configuración del sistema de inferencia difusa se desarrolla a partir de los parámetros que se indican en la Tabla 9.8, donde se relaciona el valor dado a cada uno. Estos parámetros son ingresados en las funciones de MATLAB **sugfis**, para las configuraciones sin agrupamiento difuso y **genfis**, para las configuraciones con agrupamiento.

Tabla 9.8: Parámetros sistema de inferencia difusa tipo Sugeno.
Elaboración Propia.

PARÁMETRO	VALOR SIN CLUSTER DIFUSO	VALOR CLUSTER DIFUSO
Método de operador difuso AND.	El producto de valores de entrada difusos.	
Método de operador difuso OR.	El máximo de valores de entrada difusos.	OR probabilístico de valores de entrada difusos.
Método de defuzzificación para calcular valores de salida nítidos.	Promedio ponderado de todas las salidas de reglas.	
Método de implicación para calcular el conjunto difuso consecuente.	Escala la función de pertenencia consecuente por el valor del resultado antecedente.	
Método de agregación para combinar consecuentes de reglas.	Suma de conjuntos difusos consecuentes.	

Sistemas de inferencia difusa tipo ANFIS

La configuración del sistema de inferencia difusa tipo ANFIS se basa en las configuraciones de los sistemas de inferencia difusa tipo Sugeno vistas anteriormente, los parámetros para su ejecución se indican en la Tabla 9.9, donde se relaciona el valor dado a cada uno. Estos parámetros son ingresados en la función de MATLAB **anfisOptions** junto con los datos de validación para evitar sobre ajustes.

Tabla 9.9: Parámetros sistema de inferencia difusa tipo ANFIS.
Elaboración Propia.

PARÁMETRO	VALOR
Número máximo de épocas de entrenamiento	200
Tamaño del paso de entrenamiento inicial	0.1
Método de optimización	Método híbrido con Backpropagation para la entrada y mínimos cuadrados para la salida.

Entradas, salidas y reglas del modelo basado en datos históricos de humedad

El modelo basado en datos históricos toma tres desplazamientos en el tiempo de los datos de humedad para poder predecir su valor actual, para ello se proponen tres conjuntos difusos de entrada que corresponden a los siguientes registros de datos:

- hum-1 : Humedad con un desplazamiento en el tiempo.
- hum-2 : Humedad con dos desplazamientos en el tiempo.
- hum-3 : Humedad con tres desplazamientos en el tiempo.

Cada conjunto difuso esta conformado por cinco funciones de pertenencia que representan los valores de humedad: muy baja, baja, media, alta y muy alta. Las funciones de pertenencia para la entrada, de todos los tipos de sistemas de inferencia difusa, y para la salida del tipo Mamdani son **gaussmf**. Para la salida de los sistemas de inferencia de tipo Sugeno y ANFIS las funciones de pertenencia son **linear**. Tanto para el modelo con agrupamiento difuso como el modelo sin agrupamiento las funciones de pertenencia están homogéneamente distribuidas entre el rango de valores que toma la humedad 0,4 y 1,0.

Las reglas se definen automáticamente usando agrupamiento difuso, relacionando cada una de las entradas con las salidas de manera uniforme. Por otra parte, las reglas implementadas en los modelos sin uso de agrupamiento difuso se definen a partir del análisis exploratorio como se muestra a continuación:

- Si la humedad de los dos instantes anteriores es muy baja y la del tercer instante anterior es baja entonces la humedad actual es muy baja.
- Si la humedad de los dos instantes anteriores es baja y la del tercer instante anterior es media entonces la humedad actual es baja.
- Si la humedad de los dos instantes anteriores es media y la del tercer instante anterior es baja entonces la humedad actual es media.
- Si la humedad de los dos instantes anteriores es alta y la del tercer instante es media entonces la humedad actual es alta.
- Si la humedad de los dos instantes anteriores es muy alta y la del tercer instante es alta entonces la humedad actual es muy alta.

Entradas, salidas y reglas del modelo basado en variables correlacionadas

Los modelos basados en variables correlacionadas utilizan como entrada los datos actuales y dos desplazamientos en el tiempo de las variables de temperatura, concentración de CO_2 y humedad del suelo para la predicción de la humedad. Para cada una de las entradas se proponen los siguientes conjuntos difusos de entrada que corresponden a los siguientes registros de datos:

- temp : Temperatura actual.
- temp-1 : Temperatura con un desplazamiento en el tiempo.
- temp-2 : Temperatura con dos desplazamientos en el tiempo.
- co2_ppm : Concentración de CO_2 actual.
- co2_ppm-1 : Concentración de CO_2 con un desplazamiento en el tiempo.
- co2_ppm-2 : Concentración de CO_2 con dos desplazamientos en el tiempo.
- ground_humidity_per : Humedad del suelo actual.
- ground_humidity_per-1 : Humedad del suelo con un desplazamiento en el tiempo.
- ground_humidity_per-2 : Humedad del suelo con dos desplazamientos en el tiempo.

Cada conjunto difuso en la entrada para los modelos sin agrupamiento difuso esta conformado por tres funciones de pertenencia que representan los valores de la variable: baja, media y alta y son **gaussmf**. Por otra parte para las entradas de los modelos con agrupamiento se componen de cinco funciones de pertenencia **gaussmf**.

El conjunto difuso en la salida añade dos funciones de pertenencia para los valores muy bajos y muy altos y en los modelos Sugeno y Anfis presenta cinco funciones de pertenencia **linear** y en los modelos Mamdani **trimf**. Por otra parte, para los modelos con agrupamiento difuso de tipo Mamdani, la salida esta compuesta por funciones de pertenencia **gaussmf**. Tanto las funciones de pertenencia en los conjuntos difuso de entrada como de salidas están distribuidas homogéneamente entre el rango de valores para:

- Temperatura entre 0,2 y 0,8
- Concentración de CO_2 entre 0,0 y 0,4
- Humedad del suelo entre 0,3 y 0,8
- Humedad entre 0,4 y 1,0

Las reglas implementadas en los modelos sin uso de agrupamiento difuso se definen a partir del análisis exploratorio como se muestra a continuación:

- Si la temperatura histórica y actual es alta, la concentración de CO_2 con dos desplazamientos es media y la anterior y actual baja y la humedad del suelo histórica y actual es baja entonces la humedad es muy baja.
- Si la temperatura con dos desplazamientos es media y la anterior y actual es alta, la concentración de CO_2 histórica es baja y la actual media y la humedad del suelo con dos desplazamientos es baja y la anterior y actual es media entonces la humedad es baja.

- Si la temperatura histórica y actual es media, la concentración de CO_2 histórica y actual es media y la humedad del suelo histórica y actual es media entonces la humedad es media.
- Si la temperatura con dos desplazamientos es media y la anterior y actual es baja, la concentración de CO_2 histórica es alta y la actual media y la humedad del suelo con dos desplazamientos es alta y la anterior y actual es media entonces la humedad es alta.
- Si la temperatura histórica y actual es baja, la concentración de CO_2 con dos desplazamientos es media y la anterior y actual alta y la humedad del suelo histórica y actual es alta entonces la humedad es muy alta.

9.3.2. Configuración mecanismos de optimización

Se utiliza una combinación de técnicas heurísticas y exactas para optimizar todas las propuestas de modelos elaborados, donde se optimizan los valores que determinan la forma de las entradas y salidas, para ello se realiza una implementación de una función híbrida que ejecuta una minimización por algoritmo de punto interior después de que termina el algoritmo genético. Los parámetros para la implementación del algoritmo genético se indican en la Tabla 9.10, donde se relaciona el parámetro y su valor que será ingresado al usar la función **optimoptions**.

Tabla 9.10: Parámetros algoritmo genético. Elaboración Propia.

PARÁMETRO	VALOR
Tamaño de la población	50
Número máximo de iteraciones antes de que el algoritmo se detenga	200
Individuos de la generación actual que tienen garantizado sobrevivir hasta la próxima generación	2
Fración de la población en la próxima generación, sin incluir a los que se les garantiza la supervivencia, que crea la función cruce	0.8
Tiempo para que el algoritmo se detenga después de ejecutarse en segundos	300

Para la implementación del algoritmo de punto interior se establecen los valores para sus parámetros en la Tabla 9.11, estos serán ingresados en la función **hybridFcn**.

Tabla 9.11: Parámetros algoritmo de punto interior. Elaboración Propia.

PARÁMETRO	VALOR
Número máximo de evaluaciones de funciones	3000
Número máximo de iteraciones antes de que el algoritmo se detenga	30

9.3.3. Configuración mecanismos de agrupamiento difuso

El agrupamiento difuso se define a través de la función **genfisOptions** de Matlab, esta función recibe un tipo de agrupamiento difuso, en este caso se usa el método de **FCMClustering** el cual puede ser implementado tanto con sistemas de inferencia difusa de tipo Mamdani como Sugeno. Los parámetros para la configuración del agrupamiento difuso se muestran en la Tabla 9.12, donde se relaciona el valor de cada uno.

Tabla 9.12: Parámetros método de agrupamiento difuso FCMClustering. Elaboración Propia.

PARÁMETRO	VALOR
Número de clusters	5
Exponente de la matriz de partición difusa	2.0
Número máximo de iteraciones	100
Mejora mínima en la función objetivo	1e-5

9.4. VALIDACIÓN DEL MODELO

Se desarrollan 6 modelos tanto para la propuesta basada en datos históricos de humedad con la basada en variables correlacionadas, cada modelo es ejecutado en 30 oportunidades y se obtienen los valores de sus errores máximo, mínimo, MSE, RMSE y MAE, tanto para los conjuntos de datos de entrenamiento como de validación. Posteriormente se escoge el modelo con el mayor grado de interpretación y precisión y se realiza una prueba t de dos muestras para determinar si los datos obtenidos por la predicción en relación con los datos reales provienen de la misma distribución con la misma media y varianza.

9.4.1. Modelo basado en datos históricos de humedad

Para los modelos basados en datos históricos de humedad se utilizan un total de 17.318 registros, de los cuales el 70% se usa para la fase de entrenamiento y el 30% restante para la validación. Se proponen 6 modelos implementando los sistemas de inferencia difusa tipo Mamdani, Sugeno y ANFIS, y sus correspondientes con el uso de agrupamiento difuso, optimizados por un método híbrido que combina algoritmo genético y algoritmo de punto interior. Se registran en la Tabla 9.13 para cada una de las ejecuciones aleatorias de los modelos sus valores de error máximo, mínimo, MSE, RMSE, MAE y un promedio aritmético de los MSE para las fases de entrenamiento y validación donde se resalta el modelo que presente el menor valor de MSE promedio.

Tabla 9.13: Valores de error para las ejecuciones de los modelos de predicción basados en datos históricos de humedad. Elaboración Propia.

EJECUCIONES	ENTRENAMIENTO					VALIDACIÓN					\overline{MSE}	
	MSE	RMSE	MAE	MIN	MAX	MSE	RMSE	MAE	MIN	MAX		
Sugeno-Cluster	E1	5,032,E-04	2,243,E-02	2,037,E-04	1,335,E-06	9,892,E-01	1,860,E-04	1,364,E-02	1,892,E-04	5,900,E-06	2,554,E-01	3,446,E-04
	E2	5,031,E-04	2,243,E-02	2,037,E-04	3,370,E-06	9,892,E-01	1,842,E-04	1,357,E-02	1,883,E-04	6,086,E-07	2,555,E-01	3,436,E-04
	E3	4,647,E-04	2,156,E-02	1,958,E-04	5,139,E-07	7,419,E-01	1,837,E-04	1,355,E-02	1,880,E-04	4,519,E-07	2,554,E-01	3,242,E-04
	E4	4,831,E-04	2,198,E-02	1,996,E-04	8,315,E-07	8,467,E-01	1,819,E-04	1,349,E-02	1,871,E-04	6,816,E-06	2,554,E-01	3,325,E-04
	E5	5,020,E-04	2,241,E-02	2,035,E-04	3,133,E-07	9,892,E-01	1,833,E-04	1,354,E-02	1,878,E-04	1,983,E-06	2,554,E-01	3,427,E-04
	E6	5,032,E-04	2,243,E-02	2,037,E-04	1,189,E-06	9,892,E-01	1,826,E-04	1,351,E-02	1,875,E-04	1,612,E-06	2,554,E-01	3,429,E-04
	E7	4,962,E-04	2,228,E-02	2,023,E-04	1,796,E-07	9,380,E-01	1,823,E-04	1,350,E-02	1,873,E-04	5,399,E-07	2,554,E-01	3,393,E-04
	E8	4,675,E-04	2,162,E-02	1,964,E-04	1,309,E-06	6,924,E-01	1,824,E-04	1,351,E-02	1,874,E-04	1,260,E-06	2,554,E-01	3,249,E-04
	E9	4,817,E-04	2,195,E-02	1,993,E-04	7,719,E-07	8,331,E-01	1,871,E-04	1,368,E-02	1,898,E-04	3,620,E-06	2,554,E-01	3,344,E-04
	E10	4,990,E-04	2,234,E-02	2,029,E-04	9,191,E-07	9,892,E-01	1,806,E-04	1,344,E-02	1,864,E-04	6,816,E-06	2,554,E-01	3,398,E-04
	E11	5,001,E-04	2,236,E-02	2,031,E-04	1,528,E-07	9,892,E-01	1,842,E-04	1,357,E-02	1,883,E-04	5,627,E-06	2,554,E-01	3,422,E-04
	E12	5,023,E-04	2,241,E-02	2,036,E-04	1,123,E-06	9,892,E-01	1,809,E-04	1,345,E-02	1,866,E-04	6,854,E-06	2,554,E-01	3,416,E-04
	E13	4,637,E-04	2,153,E-02	1,956,E-04	4,733,E-08	6,252,E-01	1,812,E-04	1,346,E-02	1,868,E-04	1,197,E-05	2,556,E-01	3,225,E-04
	E14	5,003,E-04	2,237,E-02	2,032,E-04	9,780,E-07	9,892,E-01	1,810,E-04	1,346,E-02	1,867,E-04	6,816,E-06	2,554,E-01	3,407,E-04
	E15	4,226,E-04	2,056,E-02	1,867,E-04	9,780,E-07	5,166,E-01	1,810,E-04	1,346,E-02	1,867,E-04	6,816,E-06	2,554,E-01	3,018,E-04
	E16	4,675,E-04	2,162,E-02	1,964,E-04	1,309,E-06	6,924,E-01	1,824,E-04	1,351,E-02	1,874,E-04	1,260,E-06	2,554,E-01	3,249,E-04
	E17	4,817,E-04	2,195,E-02	1,993,E-04	7,719,E-07	8,330,E-01	1,871,E-04	1,368,E-02	1,898,E-04	3,620,E-06	2,554,E-01	3,344,E-04
	E18	5,032,E-04	2,243,E-02	2,037,E-04	8,523,E-08	9,892,E-01	1,855,E-04	1,362,E-02	1,890,E-04	3,459,E-06	2,555,E-01	3,443,E-04
	E19	4,998,E-04	2,236,E-02	2,030,E-04	1,341,E-06	9,892,E-01	1,836,E-04	1,355,E-02	1,880,E-04	3,414,E-06	2,554,E-01	3,417,E-04
	E20	4,280,E-04	2,069,E-02	1,879,E-04	1,493,E-06	5,166,E-01	1,827,E-04	1,352,E-02	1,875,E-04	2,808,E-06	2,554,E-01	3,053,E-04
	E21	5,021,E-04	2,241,E-02	2,035,E-04	1,126,E-06	9,892,E-01	1,847,E-04	1,359,E-02	1,886,E-04	1,265,E-06	2,554,E-01	3,434,E-04
	E22	4,823,E-04	2,196,E-02	1,995,E-04	1,272,E-06	8,486,E-01	1,837,E-04	1,355,E-02	1,880,E-04	7,476,E-06	2,554,E-01	3,330,E-04
	E23	4,675,E-04	2,162,E-02	1,964,E-04	1,309,E-06	6,924,E-01	1,824,E-04	1,351,E-02	1,874,E-04	1,260,E-06	2,554,E-01	3,249,E-04
	E24	4,817,E-04	2,195,E-02	1,993,E-04	7,719,E-07	8,331,E-01	1,871,E-04	1,368,E-02	1,898,E-04	3,620,E-06	2,554,E-01	3,344,E-04
	E25	4,990,E-04	2,234,E-02	2,029,E-04	9,191,E-07	9,892,E-01	1,806,E-04	1,344,E-02	1,864,E-04	6,816,E-06	2,554,E-01	3,398,E-04
	E26	5,001,E-04	2,236,E-02	2,031,E-04	1,528,E-07	9,892,E-01	1,842,E-04	1,357,E-02	1,883,E-04	5,627,E-06	2,554,E-01	3,422,E-04
	E27	5,023,E-04	2,241,E-02	2,036,E-04	1,123,E-06	9,892,E-01	1,809,E-04	1,345,E-02	1,866,E-04	6,854,E-06	2,554,E-01	3,416,E-04
	E28	4,863,E-04	2,205,E-02	2,003,E-04	1,073,E-06	8,752,E-01	1,812,E-04	1,346,E-02	1,868,E-04	9,863,E-06	2,556,E-01	3,338,E-04
	E29	5,024,E-04	2,242,E-02	2,036,E-04	7,610,E-08	9,880,E-01	1,869,E-04	1,367,E-02	1,897,E-04	5,498,E-08	2,554,E-01	3,447,E-04
	E30	5,032,E-04	2,243,E-02	2,037,E-04	8,036,E-08	9,892,E-01	1,833,E-04	1,354,E-02	1,879,E-04	3,259,E-06	2,554,E-01	3,433,E-04
	E1	4,103,E-04	2,026,E-02	1,840,E-04	4,289,E-07	5,210,E-01	1,823,E-04	1,350,E-02	1,874,E-04	1,389,E-07	2,554,E-01	2,963,E-04
	E2	4,158,E-04	2,039,E-02	1,852,E-04	4,487,E-06	5,202,E-01	1,794,E-04	1,340,E-02	1,859,E-04	1,584,E-05	2,555,E-01	2,976,E-04
	E3	4,099,E-04	2,025,E-02	1,839,E-04	3,228,E-06	5,206,E-01	1,835,E-04	1,355,E-02	1,879,E-04	9,390,E-06	2,555,E-01	2,967,E-04
	E4	4,151,E-04	2,037,E-02	1,850,E-04	1,900,E-06	5,205,E-01	1,831,E-04	1,353,E-02	1,878,E-04	1,712,E-06	2,555,E-01	2,991,E-04
	E5	4,125,E-04	2,031,E-02	1,845,E-04	6,695,E-07	5,210,E-01	1,825,E-04	1,351,E-02	1,874,E-04	6,627,E-07	2,556,E-01	2,975,E-04
	E6	4,160,E-04	2,040,E-02	1,852,E-04	3,217,E-07	5,209,E-01	1,841,E-04	1,357,E-02	1,882,E-04	5,284,E-06	2,555,E-01	3,000,E-04
	E7	4,131,E-04	2,033,E-02	1,846,E-04	4,972,E-07	5,205,E-01	1,819,E-04	1,349,E-02	1,871,E-04	1,147,E-05	2,556,E-01	2,975,E-04
	E8	4,117,E-04	2,029,E-02	1,843,E-04	5,448,E-07	5,207,E-01	1,811,E-04	1,346,E-02	1,867,E-04	1,343,E-06	2,554,E-01	2,964,E-04
	E9	4,068,E-04	2,017,E-02	1,832,E-04	7,758,E-10	5,209,E-01	1,830,E-04	1,353,E-02	1,877,E-04	1,214,E-05	2,556,E-01	2,949,E-04
	E10	4,126,E-04	2,031,E-02	1,845,E-04	4,135,E-08	5,209,E-01	1,808,E-04	1,345,E-02	1,866,E-04	1,267,E-06	2,554,E-01	2,967,E-04

Tabla 9.13 Valores de error para las ejecuciones de los modelos de predicción basados en datos históricos de humedad. Elaboración Propia.

EJECUCIONES		ENTRENAMIENTO					VALIDACIÓN					\overline{MSE}
		MSE	RMSE	MAE	MIN	MAX	MSE	RMSE	MAE	MIN	MAX	
ANFIS-Cluster	E11	4,129,E-04	2,032,E-02	1,846,E-04	7,115,E-08	5,210,E-01	1,829,E-04	1,353,E-02	1,876,E-04	5,100,E-06	2,555,E-01	2,979,E-04
	E12	4,117,E-04	2,029,E-02	1,843,E-04	6,354,E-07	5,207,E-01	1,818,E-04	1,348,E-02	1,871,E-04	2,516,E-05	2,555,E-01	2,967,E-04
	E13	4,164,E-04	2,041,E-02	1,853,E-04	9,776,E-07	5,206,E-01	1,813,E-04	1,346,E-02	1,868,E-04	8,763,E-07	2,554,E-01	2,988,E-04
	E14	4,123,E-04	2,031,E-02	1,844,E-04	1,583,E-06	5,207,E-01	1,827,E-04	1,352,E-02	1,875,E-04	3,564,E-06	2,555,E-01	2,975,E-04
	E15	4,111,E-04	2,028,E-02	1,842,E-04	1,690,E-07	5,207,E-01	1,816,E-04	1,348,E-02	1,870,E-04	2,550,E-05	2,555,E-01	2,964,E-04
	E16	4,117,E-04	2,029,E-02	1,843,E-04	5,448,E-07	5,207,E-01	1,811,E-04	1,346,E-02	1,867,E-04	1,343,E-06	2,554,E-01	2,964,E-04
	E17	4,143,E-04	2,036,E-02	1,849,E-04	6,330,E-08	5,210,E-01	1,813,E-04	1,346,E-02	1,868,E-04	1,352,E-06	2,555,E-01	2,978,E-04
	E18	4,129,E-04	2,032,E-02	1,846,E-04	3,233,E-07	5,211,E-01	1,824,E-04	1,351,E-02	1,874,E-04	2,664,E-06	2,555,E-01	2,977,E-04
	E19	4,108,E-04	2,027,E-02	1,841,E-04	1,122,E-07	5,208,E-01	1,809,E-04	1,345,E-02	1,866,E-04	3,206,E-05	2,554,E-01	2,958,E-04
	E20	4,153,E-04	2,038,E-02	1,851,E-04	1,063,E-06	5,209,E-01	1,818,E-04	1,348,E-02	1,871,E-04	2,554,E-06	2,554,E-01	2,986,E-04
	E21	4,124,E-04	2,031,E-02	1,844,E-04	3,907,E-08	5,210,E-01	1,805,E-04	1,344,E-02	1,864,E-04	5,060,E-07	2,554,E-01	2,964,E-04
	E22	4,078,E-04	2,019,E-02	1,834,E-04	2,981,E-07	5,209,E-01	1,861,E-04	1,364,E-02	1,893,E-04	3,553,E-06	2,555,E-01	2,970,E-04
	E23	4,117,E-04	2,029,E-02	1,843,E-04	5,448,E-07	5,207,E-01	1,811,E-04	1,346,E-02	1,867,E-04	1,343,E-06	2,554,E-01	2,964,E-04
	E24	4,068,E-04	2,017,E-02	1,832,E-04	7,758,E-10	5,209,E-01	1,830,E-04	1,353,E-02	1,877,E-04	1,214,E-05	2,556,E-01	2,949,E-04
	E25	4,126,E-04	2,031,E-02	1,845,E-04	4,135,E-08	5,209,E-01	1,808,E-04	1,345,E-02	1,866,E-04	1,267,E-06	2,554,E-01	2,967,E-04
	E26	4,129,E-04	2,032,E-02	1,846,E-04	7,115,E-08	5,210,E-01	1,829,E-04	1,353,E-02	1,876,E-04	5,100,E-06	2,555,E-01	2,979,E-04
E27	4,117,E-04	2,029,E-02	1,843,E-04	6,354,E-07	5,207,E-01	1,818,E-04	1,348,E-02	1,871,E-04	2,516,E-05	2,555,E-01	2,967,E-04	
E28	4,170,E-04	2,042,E-02	1,855,E-04	6,110,E-07	5,207,E-01	1,789,E-04	1,338,E-02	1,856,E-04	8,029,E-06	2,556,E-01	2,980,E-04	
E29	4,059,E-04	2,015,E-02	1,830,E-04	1,496,E-06	5,210,E-01	3,141,E-04	1,772,E-02	2,459,E-04	2,044,E-06	8,182,E-01	3,600,E-04	
E30	4,170,E-04	2,042,E-02	1,855,E-04	4,432,E-06	5,211,E-01	1,798,E-04	1,341,E-02	1,860,E-04	1,714,E-05	2,555,E-01	2,984,E-04	
Mamdani-Cluster	E1	2,792,E-03	5,284,E-02	4,799,E-04	2,445,E-05	4,648,E-01	2,596,E-03	5,095,E-02	7,068,E-04	1,418,E-04	2,604,E-01	2,694,E-03
	E2	2,951,E-03	5,433,E-02	4,934,E-04	2,358,E-05	4,165,E-01	1,600,E-03	4,000,E-02	5,549,E-04	1,854,E-05	2,673,E-01	2,275,E-03
	E3	2,789,E-03	5,281,E-02	4,797,E-04	5,369,E-05	4,650,E-01	1,963,E-03	4,431,E-02	6,148,E-04	5,679,E-05	2,409,E-01	2,376,E-03
	E4	2,809,E-03	5,300,E-02	4,814,E-04	1,000,E-15	4,518,E-01	1,930,E-03	4,393,E-02	6,096,E-04	1,975,E-05	2,249,E-01	2,370,E-03
	E5	2,795,E-03	5,287,E-02	4,802,E-04	7,110,E-06	4,553,E-01	1,828,E-03	4,276,E-02	5,932,E-04	7,541,E-05	2,177,E-01	2,312,E-03
	E6	2,619,E-03	5,117,E-02	4,648,E-04	2,806,E-05	4,470,E-01	1,815,E-03	4,260,E-02	5,910,E-04	1,528,E-04	2,404,E-01	2,217,E-03
	E7	2,676,E-03	5,173,E-02	4,698,E-04	3,557,E-06	4,613,E-01	1,843,E-03	4,293,E-02	5,956,E-04	4,212,E-05	2,404,E-01	2,259,E-03
	E8	2,792,E-03	5,284,E-02	4,799,E-04	2,445,E-05	4,648,E-01	2,596,E-03	5,095,E-02	7,068,E-04	1,418,E-04	2,604,E-01	2,694,E-03
	E9	2,951,E-03	5,433,E-02	4,934,E-04	2,358,E-05	4,165,E-01	1,600,E-03	4,000,E-02	5,549,E-04	1,854,E-05	2,673,E-01	2,275,E-03
	E10	2,789,E-03	5,281,E-02	4,797,E-04	5,369,E-05	4,650,E-01	1,963,E-03	4,431,E-02	6,148,E-04	5,679,E-05	2,409,E-01	2,376,E-03
	E11	2,809,E-03	5,300,E-02	4,814,E-04	1,000,E-15	4,518,E-01	1,930,E-03	4,393,E-02	6,096,E-04	1,975,E-05	2,249,E-01	2,370,E-03
	E12	2,795,E-03	5,287,E-02	4,802,E-04	7,110,E-06	4,553,E-01	1,828,E-03	4,276,E-02	5,932,E-04	7,541,E-05	2,177,E-01	2,312,E-03
	E13	2,619,E-03	5,117,E-02	4,648,E-04	2,806,E-05	4,470,E-01	1,815,E-03	4,260,E-02	5,910,E-04	1,528,E-04	2,404,E-01	2,217,E-03
	E14	2,676,E-03	5,173,E-02	4,698,E-04	3,557,E-06	4,613,E-01	1,843,E-03	4,293,E-02	5,956,E-04	4,212,E-05	2,404,E-01	2,259,E-03
	E15	2,774,E-03	5,267,E-02	4,784,E-04	1,674,E-05	4,649,E-01	1,932,E-03	4,395,E-02	6,098,E-04	1,509,E-04	2,404,E-01	2,353,E-03
	E16	2,792,E-03	5,284,E-02	4,799,E-04	2,445,E-05	4,648,E-01	2,596,E-03	5,095,E-02	7,068,E-04	1,418,E-04	2,604,E-01	2,694,E-03
E17	2,951,E-03	5,433,E-02	4,934,E-04	2,358,E-05	4,165,E-01	1,600,E-03	4,000,E-02	5,549,E-04	1,854,E-05	2,673,E-01	2,275,E-03	
E18	2,789,E-03	5,281,E-02	4,797,E-04	5,369,E-05	4,650,E-01	1,963,E-03	4,431,E-02	6,148,E-04	5,679,E-05	2,409,E-01	2,376,E-03	
E19	2,809,E-03	5,300,E-02	4,814,E-04	1,000,E-15	4,518,E-01	1,930,E-03	4,393,E-02	6,096,E-04	1,975,E-05	2,249,E-01	2,370,E-03	
E20	2,795,E-03	5,287,E-02	4,802,E-04	7,110,E-06	4,553,E-01	1,828,E-03	4,276,E-02	5,932,E-04	7,541,E-05	2,177,E-01	2,312,E-03	
E21	2,619,E-03	5,117,E-02	4,648,E-04	2,806,E-05	4,470,E-01	1,815,E-03	4,260,E-02	5,910,E-04	1,528,E-04	2,404,E-01	2,217,E-03	
E22	2,676,E-03	5,173,E-02	4,698,E-04	3,557,E-06	4,613,E-01	1,843,E-03	4,293,E-02	5,956,E-04	4,212,E-05	2,404,E-01	2,259,E-03	

Tabla 9.13 Valores de error para las ejecuciones de los modelos de predicción basados en datos históricos de humedad. Elaboración Propia.

EJECUCIONES	ENTRENAMIENTO					VALIDACIÓN					\overline{MSE}	
	MSE	RMSE	MAE	MIN	MAX	MSE	RMSE	MAE	MIN	MAX		
	E23	2,792,E-03	5,284,E-02	4,799,E-04	2,445,E-05	4,648,E-01	2,596,E-03	5,095,E-02	7,068,E-04	1,418,E-04	2,604,E-01	2,694,E-03
	E24	2,951,E-03	5,433,E-02	4,934,E-04	2,358,E-05	4,165,E-01	1,600,E-03	4,000,E-02	5,549,E-04	1,854,E-05	2,673,E-01	2,275,E-03
	E25	2,789,E-03	5,281,E-02	4,797,E-04	5,369,E-05	4,650,E-01	1,963,E-03	4,431,E-02	6,148,E-04	5,679,E-05	2,409,E-01	2,376,E-03
	E26	2,809,E-03	5,300,E-02	4,814,E-04	1,000,E-15	4,518,E-01	1,930,E-03	4,393,E-02	6,096,E-04	1,975,E-05	2,249,E-01	2,370,E-03
	E27	2,795,E-03	5,287,E-02	4,802,E-04	7,110,E-06	4,553,E-01	1,828,E-03	4,276,E-02	5,932,E-04	7,541,E-05	2,177,E-01	2,312,E-03
	E28	2,785,E-03	5,277,E-02	4,793,E-04	1,249,E-06	4,470,E-01	1,878,E-03	4,334,E-02	6,013,E-04	1,035,E-04	3,212,E-01	2,331,E-03
	E29	2,728,E-03	5,223,E-02	4,744,E-04	8,593,E-06	4,650,E-01	1,857,E-03	4,310,E-02	5,979,E-04	5,613,E-05	2,404,E-01	2,293,E-03
	E30	2,801,E-03	5,292,E-02	4,806,E-04	2,000,E-05	4,596,E-01	2,015,E-03	4,489,E-02	6,228,E-04	1,380,E-04	2,416,E-01	2,408,E-03
Sugeno	E1	5,023,E-04	2,241,E-02	2,036,E-04	1,908,E-06	8,492,E-01	1,886,E-04	1,373,E-02	1,905,E-04	2,652,E-05	2,543,E-01	3,455,E-04
	E2	4,717,E-04	2,172,E-02	1,973,E-04	1,708,E-06	5,339,E-01	1,887,E-04	1,374,E-02	1,906,E-04	1,142,E-06	2,582,E-01	3,302,E-04
	E3	4,816,E-04	2,194,E-02	1,993,E-04	4,946,E-07	5,072,E-01	1,911,E-04	1,382,E-02	1,918,E-04	2,365,E-07	2,549,E-01	3,363,E-04
	E4	5,121,E-04	2,263,E-02	2,055,E-04	1,274,E-06	5,055,E-01	2,067,E-04	1,438,E-02	1,995,E-04	1,377,E-05	2,559,E-01	3,594,E-04
	E5	4,967,E-04	2,229,E-02	2,024,E-04	6,527,E-08	5,756,E-01	1,830,E-04	1,353,E-02	1,877,E-04	7,213,E-06	2,558,E-01	3,399,E-04
	E6	5,294,E-04	2,301,E-02	2,090,E-04	5,492,E-06	8,359,E-01	1,902,E-04	1,379,E-02	1,913,E-04	7,091,E-06	2,541,E-01	3,598,E-04
	E7	5,126,E-04	2,264,E-02	2,056,E-04	2,153,E-06	5,213,E-01	2,097,E-04	1,448,E-02	2,009,E-04	4,755,E-06	2,538,E-01	3,612,E-04
	E8	4,994,E-04	2,235,E-02	2,030,E-04	6,759,E-07	5,890,E-01	1,849,E-04	1,360,E-02	1,886,E-04	5,945,E-06	2,543,E-01	3,421,E-04
	E9	4,793,E-04	2,189,E-02	1,988,E-04	5,241,E-07	5,224,E-01	1,939,E-04	1,392,E-02	1,932,E-04	5,780,E-05	2,555,E-01	3,366,E-04
	E10	4,795,E-04	2,190,E-02	1,989,E-04	2,300,E-07	5,292,E-01	1,816,E-04	1,348,E-02	1,870,E-04	1,117,E-05	2,553,E-01	3,305,E-04
	E11	4,609,E-04	2,147,E-02	1,950,E-04	1,880,E-06	5,129,E-01	1,886,E-04	1,373,E-02	1,905,E-04	2,636,E-05	2,552,E-01	3,247,E-04
	E12	4,895,E-04	2,213,E-02	2,010,E-04	1,037,E-06	5,436,E-01	1,852,E-04	1,361,E-02	1,888,E-04	5,435,E-07	2,553,E-01	3,374,E-04
	E13	4,503,E-04	2,122,E-02	1,927,E-04	2,102,E-07	5,111,E-01	1,838,E-04	1,356,E-02	1,881,E-04	1,118,E-06	2,565,E-01	3,171,E-04
	E14	7,297,E-04	2,701,E-02	2,453,E-04	1,960,E-06	7,651,E-01	2,338,E-04	1,529,E-02	2,121,E-04	3,084,E-06	2,557,E-01	4,818,E-04
	E15	5,366,E-04	2,316,E-02	2,104,E-04	6,873,E-06	8,383,E-01	1,999,E-04	1,414,E-02	1,962,E-04	2,652,E-05	2,558,E-01	3,682,E-04
	E16	4,994,E-04	2,235,E-02	2,030,E-04	6,759,E-07	5,890,E-01	1,849,E-04	1,360,E-02	1,886,E-04	5,945,E-06	2,543,E-01	3,421,E-04
	E17	4,793,E-04	2,189,E-02	1,988,E-04	5,241,E-07	5,224,E-01	1,939,E-04	1,392,E-02	1,932,E-04	5,780,E-05	2,555,E-01	3,366,E-04
	E18	4,795,E-04	2,190,E-02	1,989,E-04	2,300,E-07	5,292,E-01	1,816,E-04	1,348,E-02	1,870,E-04	1,117,E-05	2,553,E-01	3,305,E-04
	E19	4,609,E-04	2,147,E-02	1,950,E-04	1,880,E-06	5,129,E-01	1,886,E-04	1,373,E-02	1,905,E-04	2,636,E-05	2,552,E-01	3,247,E-04
	E20	4,820,E-04	2,196,E-02	1,994,E-04	2,980,E-06	5,727,E-01	1,826,E-04	1,351,E-02	1,875,E-04	2,116,E-05	2,546,E-01	3,323,E-04
	E21	5,126,E-04	2,264,E-02	2,056,E-04	2,820,E-06	5,383,E-01	2,091,E-04	1,446,E-02	2,006,E-04	2,306,E-05	2,546,E-01	3,608,E-04
	E22	4,849,E-04	2,202,E-02	2,000,E-04	2,090,E-06	6,100,E-01	1,814,E-04	1,347,E-02	1,869,E-04	3,678,E-06	2,560,E-01	3,332,E-04
	E23	4,994,E-04	2,235,E-02	2,030,E-04	6,759,E-07	5,890,E-01	1,849,E-04	1,360,E-02	1,886,E-04	5,945,E-06	2,543,E-01	3,421,E-04
	E24	5,024,E-04	2,241,E-02	2,036,E-04	1,522,E-07	6,792,E-01	2,056,E-04	1,434,E-02	1,990,E-04	2,129,E-06	2,557,E-01	3,540,E-04
	E25	4,703,E-04	2,169,E-02	1,970,E-04	1,415,E-06	5,061,E-01	1,889,E-04	1,374,E-02	1,907,E-04	7,707,E-07	2,545,E-01	3,296,E-04
	E26	4,799,E-04	2,191,E-02	1,990,E-04	9,025,E-07	6,913,E-01	2,015,E-04	1,420,E-02	1,970,E-04	1,862,E-06	2,558,E-01	3,407,E-04
	E27	4,592,E-04	2,143,E-02	1,946,E-04	2,659,E-07	5,105,E-01	1,925,E-04	1,387,E-02	1,925,E-04	2,022,E-05	2,555,E-01	3,258,E-04
	E28	4,824,E-04	2,196,E-02	1,995,E-04	4,169,E-07	5,139,E-01	2,033,E-04	1,426,E-02	1,978,E-04	1,294,E-05	2,557,E-01	3,428,E-04
	E29	4,834,E-04	2,199,E-02	1,997,E-04	3,315,E-07	5,780,E-01	1,813,E-04	1,346,E-02	1,868,E-04	1,101,E-05	2,572,E-01	3,323,E-04
	E30	4,535,E-04	2,129,E-02	1,934,E-04	2,492,E-07	5,242,E-01	1,879,E-04	1,371,E-02	1,902,E-04	5,635,E-06	2,563,E-01	3,207,E-04
	E1	4,132,E-04	2,033,E-02	1,846,E-04	4,308,E-06	5,208,E-01	1,809,E-04	1,345,E-02	1,866,E-04	1,005,E-06	2,555,E-01	2,971,E-04
	E2	4,144,E-04	2,036,E-02	1,849,E-04	1,645,E-06	5,213,E-01	1,806,E-04	1,344,E-02	1,864,E-04	3,017,E-06	2,555,E-01	2,975,E-04
	E3	4,138,E-04	2,034,E-02	1,847,E-04	2,328,E-06	5,210,E-01	1,805,E-04	1,344,E-02	1,864,E-04	1,526,E-05	2,555,E-01	2,971,E-04
	E4	4,173,E-04	2,043,E-02	1,855,E-04	6,784,E-08	5,204,E-01	1,849,E-04	1,360,E-02	1,887,E-04	2,000,E-06	2,556,E-01	3,011,E-04

Tabla 9.13 Valores de error para las ejecuciones de los modelos de predicción basados en datos históricos de humedad. Elaboración Propia.

EJECUCIONES		ENTRENAMIENTO					VALIDACIÓN					\overline{MSE}	
		MSE	RMSE	MAE	MIN	MAX	MSE	RMSE	MAE	MIN	MAX		
ANFIS	E5	4,147,E-04	2,036,E-02	1,850,E-04	3,081,E-07	5,209,E-01	1,808,E-04	1,344,E-02	1,865,E-04	5,479,E-06	2,555,E-01	2,977,E-04	
	E6	4,142,E-04	2,035,E-02	1,848,E-04	4,863,E-07	5,210,E-01	1,803,E-04	1,343,E-02	1,863,E-04	1,090,E-05	2,555,E-01	2,972,E-04	
	E7	4,179,E-04	2,044,E-02	1,857,E-04	1,043,E-06	5,208,E-01	1,819,E-04	1,349,E-02	1,871,E-04	2,060,E-05	2,555,E-01	2,999,E-04	
	E8	4,091,E-04	2,023,E-02	1,837,E-04	1,175,E-06	5,212,E-01	1,820,E-04	1,349,E-02	1,872,E-04	1,711,E-05	2,556,E-01	2,955,E-04	
	E9	4,164,E-04	2,041,E-02	1,853,E-04	2,613,E-07	5,208,E-01	1,818,E-04	1,348,E-02	1,870,E-04	7,431,E-06	2,556,E-01	2,991,E-04	
	E10	4,155,E-04	2,038,E-02	1,851,E-04	4,487,E-07	5,208,E-01	1,803,E-04	1,343,E-02	1,863,E-04	2,127,E-06	2,555,E-01	2,979,E-04	
	E11	4,138,E-04	2,034,E-02	1,848,E-04	6,836,E-07	5,210,E-01	1,799,E-04	1,341,E-02	1,861,E-04	7,373,E-07	2,555,E-01	2,969,E-04	
	E12	4,162,E-04	2,040,E-02	1,853,E-04	3,262,E-06	5,206,E-01	1,832,E-04	1,353,E-02	1,878,E-04	2,180,E-05	2,555,E-01	2,997,E-04	
	E13	4,176,E-04	2,043,E-02	1,856,E-04	6,609,E-07	5,210,E-01	1,816,E-04	1,348,E-02	1,870,E-04	5,110,E-06	2,555,E-01	2,996,E-04	
	E14	4,171,E-04	2,042,E-02	1,855,E-04	1,597,E-07	5,210,E-01	1,812,E-04	1,346,E-02	1,868,E-04	1,092,E-05	2,556,E-01	2,992,E-04	
	E15	4,173,E-04	2,043,E-02	1,855,E-04	3,297,E-06	5,205,E-01	1,809,E-04	1,345,E-02	1,866,E-04	1,780,E-05	2,555,E-01	2,991,E-04	
	E16	4,091,E-04	2,023,E-02	1,837,E-04	1,175,E-06	5,212,E-01	1,820,E-04	1,349,E-02	1,872,E-04	1,711,E-05	2,556,E-01	2,955,E-04	
	E17	4,164,E-04	2,041,E-02	1,853,E-04	2,613,E-07	5,208,E-01	1,818,E-04	1,348,E-02	1,870,E-04	7,431,E-06	2,556,E-01	2,991,E-04	
	E18	4,155,E-04	2,038,E-02	1,851,E-04	4,487,E-07	5,208,E-01	1,803,E-04	1,343,E-02	1,863,E-04	2,127,E-06	2,555,E-01	2,979,E-04	
	E19	4,138,E-04	2,034,E-02	1,848,E-04	6,836,E-07	5,210,E-01	1,799,E-04	1,341,E-02	1,861,E-04	7,373,E-07	2,555,E-01	2,969,E-04	
	E20	4,135,E-04	2,033,E-02	1,847,E-04	2,216,E-06	5,208,E-01	1,820,E-04	1,349,E-02	1,872,E-04	3,131,E-06	2,555,E-01	2,977,E-04	
	E21	4,172,E-04	2,043,E-02	1,855,E-04	1,197,E-05	5,210,E-01	1,822,E-04	1,350,E-02	1,873,E-04	2,138,E-06	2,555,E-01	2,997,E-04	
	E22	4,131,E-04	2,032,E-02	1,846,E-04	2,227,E-06	5,211,E-01	1,805,E-04	1,344,E-02	1,864,E-04	9,439,E-07	2,555,E-01	2,968,E-04	
	E23	4,091,E-04	2,023,E-02	1,837,E-04	1,175,E-06	5,212,E-01	1,820,E-04	1,349,E-02	1,872,E-04	1,711,E-05	2,556,E-01	2,955,E-04	
	E24	4,138,E-04	2,034,E-02	1,848,E-04	1,605,E-07	5,209,E-01	1,809,E-04	1,345,E-02	1,866,E-04	5,971,E-06	2,555,E-01	2,973,E-04	
	E25	4,142,E-04	2,035,E-02	1,848,E-04	1,286,E-06	5,210,E-01	1,811,E-04	1,346,E-02	1,867,E-04	2,653,E-06	2,556,E-01	2,976,E-04	
	E26	4,144,E-04	2,036,E-02	1,849,E-04	3,225,E-06	5,211,E-01	1,805,E-04	1,344,E-02	1,864,E-04	6,848,E-06	2,556,E-01	2,975,E-04	
	E27	4,138,E-04	2,034,E-02	1,848,E-04	5,989,E-06	5,209,E-01	1,827,E-04	1,352,E-02	1,875,E-04	1,019,E-06	2,555,E-01	2,983,E-04	
	E28	4,136,E-04	2,034,E-02	1,847,E-04	8,450,E-07	5,209,E-01	1,809,E-04	1,345,E-02	1,866,E-04	1,456,E-06	2,555,E-01	2,972,E-04	
	E29	4,133,E-04	2,033,E-02	1,846,E-04	2,817,E-08	5,209,E-01	1,821,E-04	1,350,E-02	1,872,E-04	4,634,E-06	2,555,E-01	2,977,E-04	
	E30	4,125,E-04	2,031,E-02	1,845,E-04	3,474,E-07	5,205,E-01	1,820,E-04	1,349,E-02	1,872,E-04	3,985,E-06	2,555,E-01	2,972,E-04	
	Mamdani	E1	3,966,E-03	6,298,E-02	5,720,E-04	1,774,E-05	4,778,E-01	2,649,E-03	5,146,E-02	7,140,E-04	2,091,E-05	2,812,E-01	3,307,E-03
		E2	3,935,E-03	6,273,E-02	5,697,E-04	1,596,E-05	4,794,E-01	2,622,E-03	5,120,E-02	7,104,E-04	9,645,E-05	2,840,E-01	3,278,E-03
		E3	2,867,E-03	5,354,E-02	4,863,E-04	1,999,E-04	4,867,E-01	4,559,E-03	6,752,E-02	9,368,E-04	2,333,E-04	2,724,E-01	3,713,E-03
		E4	3,924,E-03	6,264,E-02	5,689,E-04	8,087,E-06	4,851,E-01	2,653,E-03	5,151,E-02	7,147,E-04	1,910,E-05	2,899,E-01	3,289,E-03
E5		3,455,E-03	5,878,E-02	5,339,E-04	8,276,E-05	5,891,E-01	4,003,E-03	6,327,E-02	8,778,E-04	9,499,E-04	2,916,E-01	3,729,E-03	
E6		3,908,E-03	6,251,E-02	5,678,E-04	1,730,E-05	4,795,E-01	2,684,E-03	5,181,E-02	7,188,E-04	3,964,E-05	2,843,E-01	3,296,E-03	
E7		3,784,E-03	6,152,E-02	5,587,E-04	2,580,E-05	4,803,E-01	2,634,E-03	5,132,E-02	7,120,E-04	2,710,E-05	2,613,E-01	3,209,E-03	
E8		3,966,E-03	6,298,E-02	5,720,E-04	1,774,E-05	4,778,E-01	2,649,E-03	5,146,E-02	7,140,E-04	2,091,E-05	2,812,E-01	3,307,E-03	
E9		3,935,E-03	6,273,E-02	5,697,E-04	1,596,E-05	4,794,E-01	2,622,E-03	5,120,E-02	7,104,E-04	9,645,E-05	2,840,E-01	3,278,E-03	
E10		2,867,E-03	5,354,E-02	4,863,E-04	1,999,E-04	4,867,E-01	4,559,E-03	6,752,E-02	9,368,E-04	2,333,E-04	2,724,E-01	3,713,E-03	
E11		3,924,E-03	6,264,E-02	5,689,E-04	8,087,E-06	4,851,E-01	2,653,E-03	5,151,E-02	7,147,E-04	1,910,E-05	2,899,E-01	3,289,E-03	
E12		3,455,E-03	5,878,E-02	5,339,E-04	8,276,E-05	5,891,E-01	4,003,E-03	6,327,E-02	8,778,E-04	9,499,E-04	2,916,E-01	3,729,E-03	
E13		3,908,E-03	6,251,E-02	5,678,E-04	1,730,E-05	4,795,E-01	2,684,E-03	5,181,E-02	7,188,E-04	3,964,E-05	2,843,E-01	3,296,E-03	
E14		3,784,E-03	6,152,E-02	5,587,E-04	2,580,E-05	4,803,E-01	2,634,E-03	5,132,E-02	7,120,E-04	2,710,E-05	2,613,E-01	3,209,E-03	
E15		3,573,E-03	5,978,E-02	5,429,E-04	2,140,E-05	4,787,E-01	2,412,E-03	4,911,E-02	6,813,E-04	2,828,E-05	2,579,E-01	2,993,E-03	
E16		3,966,E-03	6,298,E-02	5,720,E-04	1,774,E-05	4,778,E-01	2,649,E-03	5,146,E-02	7,140,E-04	2,091,E-05	2,812,E-01	3,307,E-03	

Tabla 9.13 Valores de error para las ejecuciones de los modelos de predicción basados en datos históricos de humedad. Elaboración Propia.

EJECUCIONES	ENTRENAMIENTO					VALIDACIÓN					\overline{MSE}
	MSE	RMSE	MAE	MIN	MAX	MSE	RMSE	MAE	MIN	MAX	
E17	3,935,E-03	6,273,E-02	5,697,E-04	1,596,E-05	4,794,E-01	2,622,E-03	5,120,E-02	7,104,E-04	9,645,E-05	2,840,E-01	3,278,E-03
E18	2,867,E-03	5,354,E-02	4,863,E-04	1,999,E-04	4,867,E-01	4,559,E-03	6,752,E-02	9,368,E-04	2,333,E-04	2,724,E-01	3,713,E-03
E19	3,924,E-03	6,264,E-02	5,689,E-04	8,087,E-06	4,851,E-01	2,653,E-03	5,151,E-02	7,147,E-04	1,910,E-05	2,899,E-01	3,289,E-03
E20	3,455,E-03	5,878,E-02	5,339,E-04	8,276,E-05	5,891,E-01	4,003,E-03	6,327,E-02	8,778,E-04	9,499,E-04	2,916,E-01	3,729,E-03
E21	3,908,E-03	6,251,E-02	5,678,E-04	1,730,E-05	4,795,E-01	2,684,E-03	5,181,E-02	7,188,E-04	3,964,E-05	2,843,E-01	3,296,E-03
E22	3,784,E-03	6,152,E-02	5,587,E-04	2,580,E-05	4,803,E-01	2,634,E-03	5,132,E-02	7,120,E-04	2,710,E-05	2,613,E-01	3,209,E-03
E23	3,966,E-03	6,298,E-02	5,720,E-04	1,774,E-05	4,778,E-01	2,649,E-03	5,146,E-02	7,140,E-04	2,091,E-05	2,812,E-01	3,307,E-03
E24	3,935,E-03	6,273,E-02	5,697,E-04	1,596,E-05	4,794,E-01	2,622,E-03	5,120,E-02	7,104,E-04	9,645,E-05	2,840,E-01	3,278,E-03
E25	2,867,E-03	5,354,E-02	4,863,E-04	1,999,E-04	4,867,E-01	4,559,E-03	6,752,E-02	9,368,E-04	2,333,E-04	2,724,E-01	3,713,E-03
E26	3,924,E-03	6,264,E-02	5,689,E-04	8,087,E-06	4,851,E-01	2,653,E-03	5,151,E-02	7,147,E-04	1,910,E-05	2,899,E-01	3,289,E-03
E27	3,455,E-03	5,878,E-02	5,339,E-04	8,276,E-05	5,891,E-01	4,003,E-03	6,327,E-02	8,778,E-04	9,499,E-04	2,916,E-01	3,729,E-03
E28	3,908,E-03	6,251,E-02	5,678,E-04	1,730,E-05	4,795,E-01	2,684,E-03	5,181,E-02	7,188,E-04	3,964,E-05	2,843,E-01	3,296,E-03
E29	3,784,E-03	6,152,E-02	5,587,E-04	2,580,E-05	4,803,E-01	2,634,E-03	5,132,E-02	7,120,E-04	2,710,E-05	2,613,E-01	3,209,E-03
E30	3,573,E-03	5,978,E-02	5,429,E-04	2,140,E-05	4,787,E-01	2,412,E-03	4,911,E-02	6,813,E-04	2,828,E-05	2,579,E-01	2,993,E-03

A partir de los valores obtenidos se muestran los promedios aritméticos de los valores de error máximo, mínimo, MSE, RMSE y MAE para los 6 modelos propuestos en la Tabla 9.14, donde se observa que los errores más bajos están presentes en los modelos tipo Sugeno y ANFIS.

Tabla 9.14: Valores promedio de error para las ejecuciones de los modelos de predicción basados en datos históricos. Elaboración Propia.

SISTEMA DE INFERENCIA DIFUSA	VALORES PROMEDIO ENTRENAMIENTO					VALORES PROMEDIO VALIDACIÓN				
	MSE	RMSE	MAE	MIN	MAX	MSE	RMSE	MAE	MIN	MAX
Sugeno-Cluster	4,867,E-04	2,206,E-02	2,003,E-04	8,971,E-07	8,771,E-01	1,833,E-04	1,354,E-02	1,878,E-04	4,278,E-06	2,554,E-01
ANFIS-Cluster	4,123,E-04	2,030,E-02	1,844,E-04	0	5,208,E-01	1,863,E-04	1,363,E-02	1,891,E-04	7,856,E-06	2,742,E-01
Mamdani-Cluster	2,784,E-03	5,276,E-02	4,792,E-04	1,922,E-05	4,525,E-01	1,944,E-03	4,399,E-02	6,103,E-04	7,609,E-05	2,444,E-01
Sugeno	4,954,E-04	2,223,E-02	2,019,E-04	1,403,E-06	5,869,E-01	1,926,E-04	1,387,E-02	1,925,E-04	1,343,E-05	2,554,E-01
ANFIS	4,144,E-04	2,036,E-02	1,849,E-04	0	5,209,E-01	1,814,E-04	1,347,E-02	1,869,E-04	7,286,E-06	2,555,E-01
Mamdani	3,683,E-03	6,061,E-02	5,505,E-04	5,043,E-05	4,956,E-01	3,068,E-03	5,502,E-02	7,634,E-04	1,867,E-04	2,792,E-01

Como se observa en la Tabla 9.13 se relaciona a continuación el modelo implementado junto con la ejecución que presenta el mejor nivel de precisión.

- Sugeno con agrupamiento difuso, ejecución 15 con un MSE promedio de 3,018 E-04 en entrenamiento y validación.
- ANFIS con agrupamiento difuso, ejecución 9 o 24 con un MSE promedio de 2,949 E-04 en entrenamiento y validación.
- Mamdani con agrupamiento difuso, ejecución 6, 13 o 21 con un MSE promedio de 2,217 E-03 en entrenamiento y validación.
- Sugeno, ejecución 13 con un MSE promedio de 3,171 E-04 en entrenamiento y validación.
- ANFIS, ejecución 8, 16 o 23 con un MSE promedio de 2,955 E-04 en entrenamiento y validación.
- Mamdani, ejecución 15 o 30 con un MSE promedio de 2,993 E-03 en entrenamiento y validación.

Los valores de humedad relativa obtenidos en la fase de entrenamiento a partir de la predicción de cada uno de los modelos respecto a los reales se muestran en la Fig. 9.1 donde el eje de las abscisas relaciona el periodo de tiempo entre el 24 de mayo hasta el 22 de julio de 2021 y el eje de las ordenadas los valores de humedad relativa en porcentaje (%).

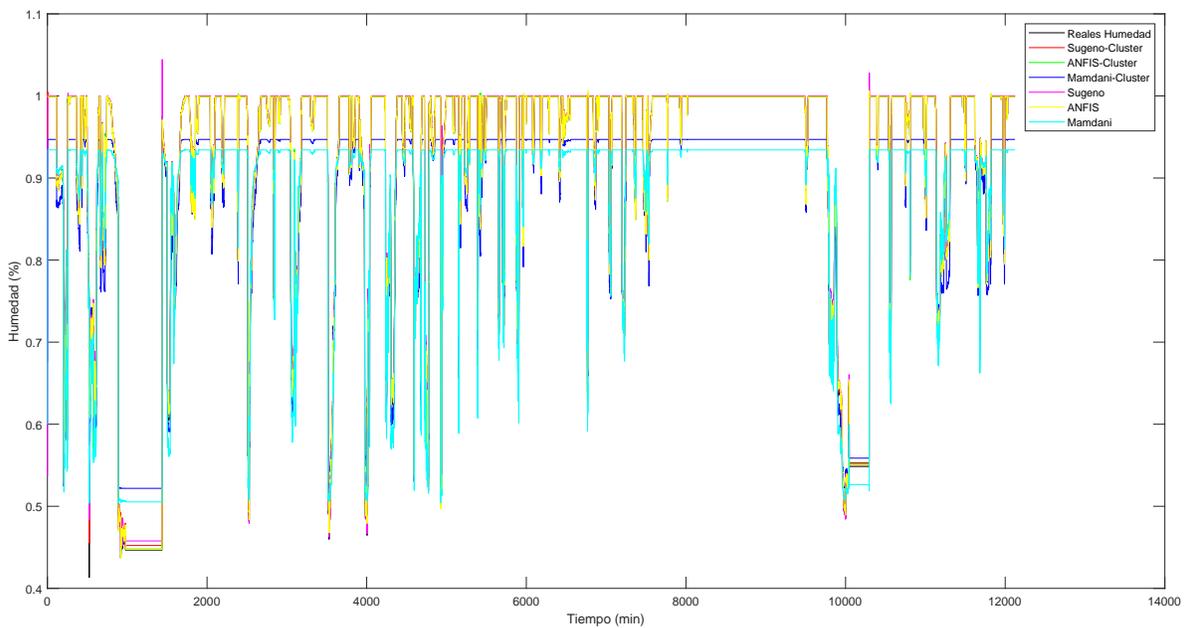


Fig. 9.1: Comparación valores reales y de los modelos basados en datos históricos en la fase de entrenamiento. Elaboración Propia. (Entorno MATLAB®).

De igual forma se muestra en la Fig. 9.2 la comparación de los valores obtenidos de la predicción de

los modelos y los reales para la fase de validación obteniendo resultados homogéneos en cada modelo con alto grado de precisión.

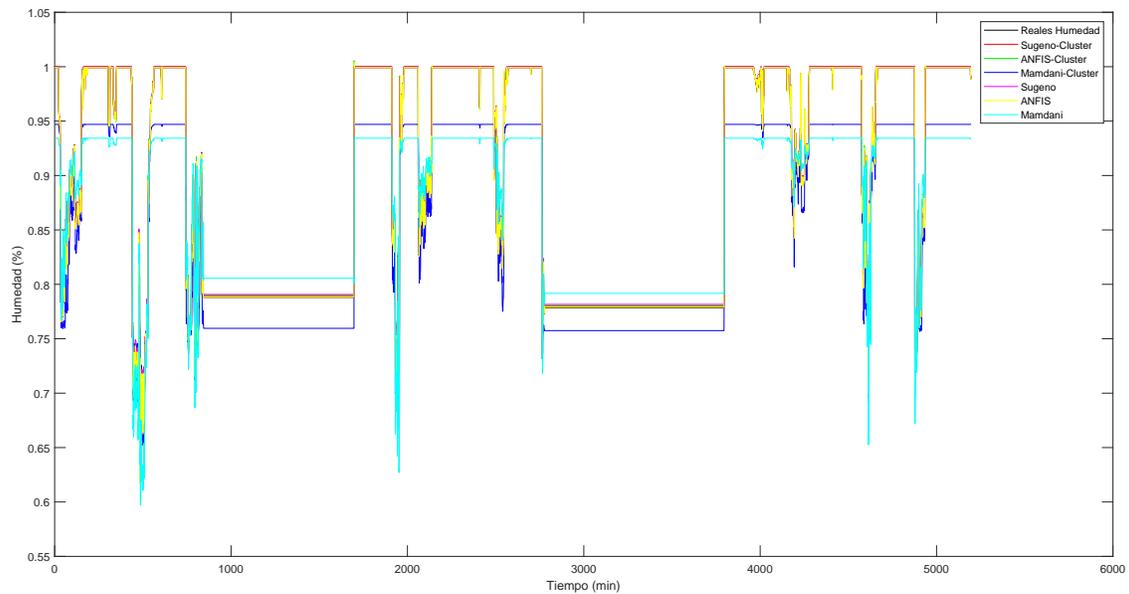


Fig. 9.2: Comparación valores reales y de los modelos basados en datos históricos en la fase de validación. Elaboración Propia. (Entorno MATLAB®).

Basado en los MSE obtenidos en cada uno de los modelos se muestra en la Fig. 9.3 la relación del error entre los datos de humedad predichos y los reales a través del tiempo, donde el eje de las abscisas corresponde al tiempo y el de las ordenadas al error.

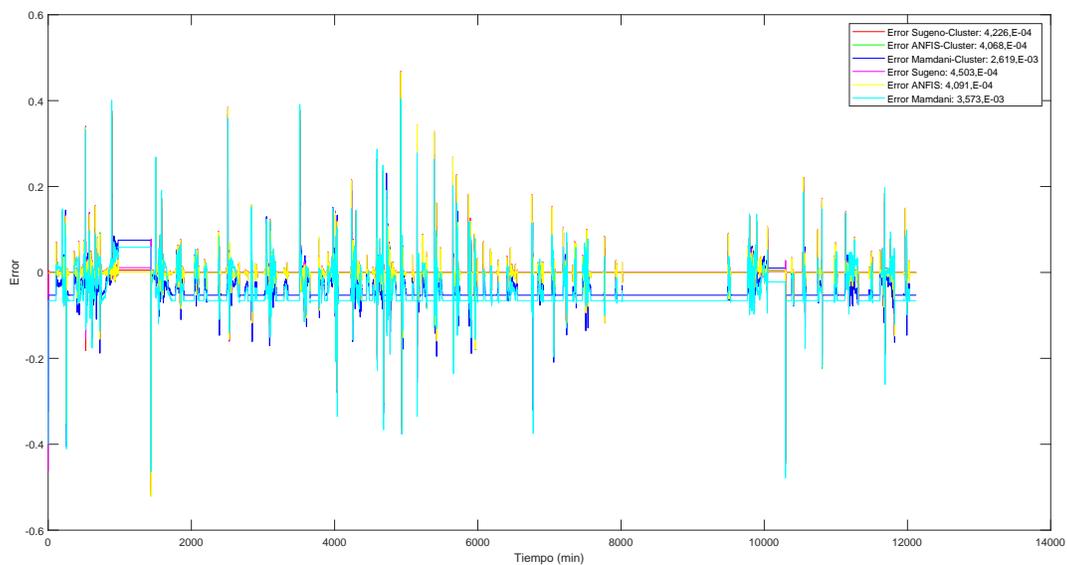


Fig. 9.3: Error valores reales con los de los modelos basados en datos históricos en la fase de entrenamiento. Elaboración Propia. (Entorno MATLAB®).

De la misma forma la Fig. 9.4 muestra la relación de error para los datos de humedad obtenidos de la predicción por los modelos y los reales a través del tiempo.

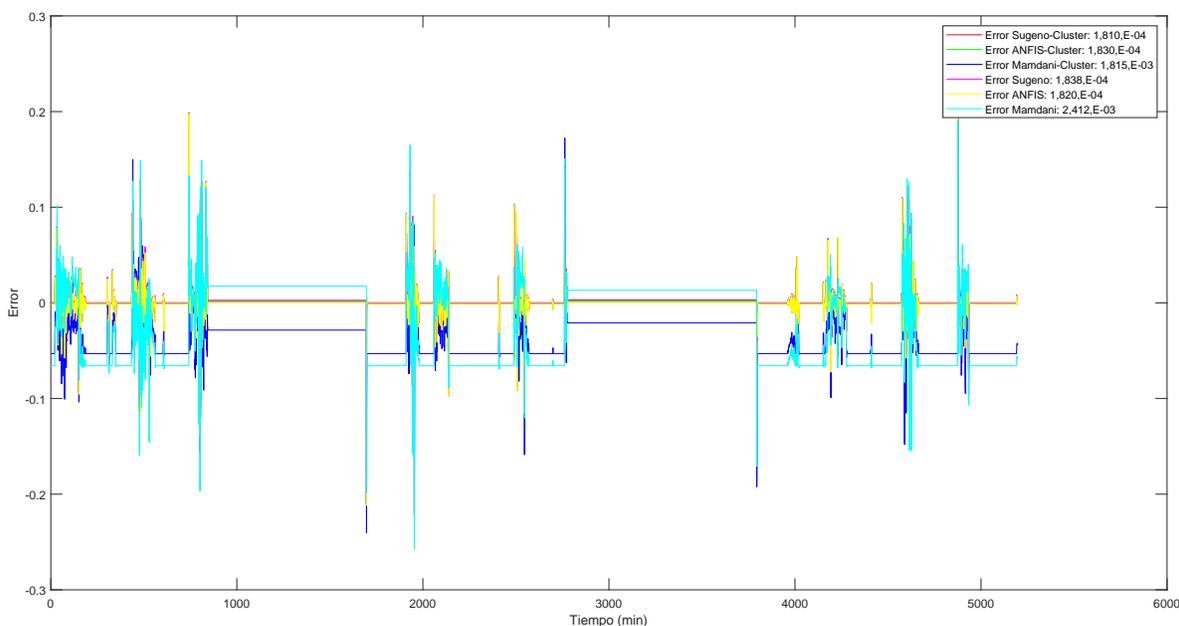


Fig. 9.4: Error valores reales con los de los modelos basados en datos históricos en la fase de validación. Elaboración Propia. (Entorno MATLAB®).

Teniendo en cuenta los resultados de precisión evidenciados en la Tabla 9.13, y que conforme al grado de interpretabilidad los modelos más interpretables son los tipo Mamdani, seguidos por los Sugeno y ANFIS, se muestra en la Tabla 9.15 el grado de precisión e interpretabilidad para cada modelo, donde se establece un valor de 1 a 6 para los valores tanto de precisión como interpretabilidad según corresponda.

Tabla 9.15: Análisis de precisión e interpretabilidad para modelos basados en datos históricos. Elaboración Propia.

SISTEMA DE INFERENCIA DIFUSA	MEJOR MSE	\overline{MSE}	PRECISIÓN	INTERPRETACIÓN	RANKING
Sugeno-Cluster	3,018,E-04	3,350,E-04	4,0	3,0	7,0
ANFIS-Cluster	2,949,E-04	2,993,E-04	5,5	1,0	6,5
Mamdani-Cluster	2,217,E-03	2,364,E-03	2,0	5,0	7,0
Sugeno	3,171,E-04	3,440,E-04	3,0	4,0	7,0
ANFIS	2,955,E-04	2,979,E-04	5,5	2,0	7,5
Mamdani	2,993,E-03	3,376,E-03	1,0	6,0	7,0

Modelo implementado en el prototipo software

El modelo que se selecciona para predicción de humedad relativa basada en datos históricos es la ejecución 8 del sistema de inferencia difusa tipo ANFIS optimizado por método híbrido usando algoritmo genético y algoritmo de punto interior. El sistema de inferencia se muestra en la Fig. 9.5, donde el conjunto de entrada del primer desplazamiento en el tiempo corresponde a la Fig. 9.5(a), los del segundo desplazamiento a la Fig. 9.5(b) y los del tercer desplazamiento a la Fig. 9.5(c).

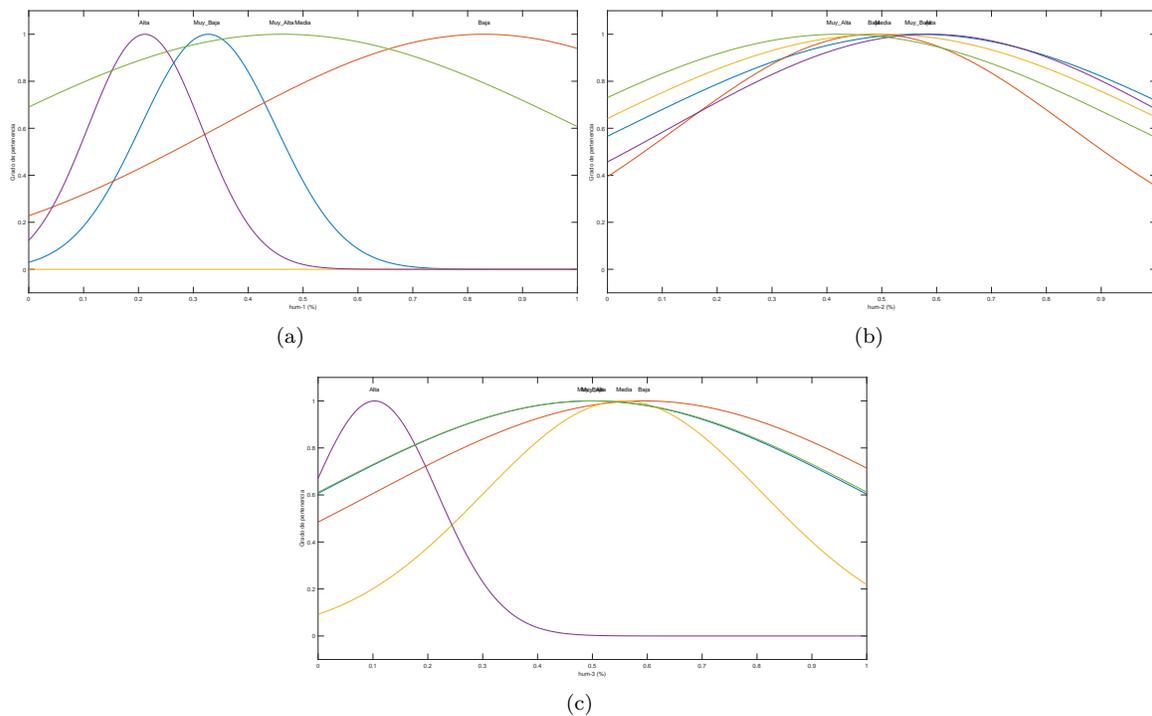


Fig. 9.5: Conjuntos difusos modelo predicción basado en datos históricos: (a) conjunto difuso con un desplazamiento en el tiempo; (b) conjunto difuso con dos desplazamientos en el tiempo; (c) conjunto difuso con tres desplazamientos en el tiempo. Elaboración propia. (Entorno MATLAB®).

La correspondencia obtenida a partir de las reglas definidas y su interacción con los conjuntos difusos se muestra en la Fig. 9.6, donde la salida corresponde al valor en la función lineal.

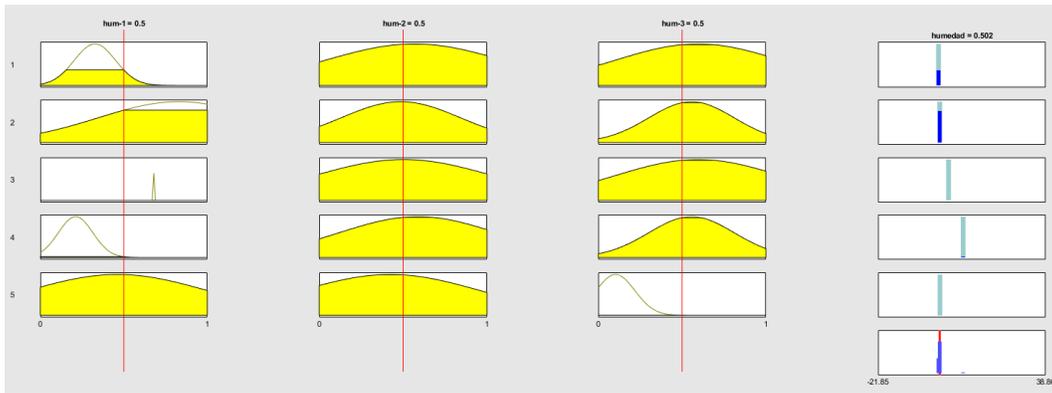


Fig. 9.6: Reglas del sistema de inferencia para modelo basado en datos históricos. Elaboración Propia. (Entorno MATLAB®).

La superficie de reglas que refleja el comportamiento de las reglas a través del espacio muestral para las variables de entrada y salida se muestra en la Fig. 9.7, donde al ser un espacio de cuatro dimensiones se muestra para la variable de salida la superficie formada por las entradas hum-1 y hum-2 en la Fig. 9.7(a), hum-1 y hum-3 en la Fig. 9.7(b) y hum-2 y hum-3 en la Fig. 9.7(c).

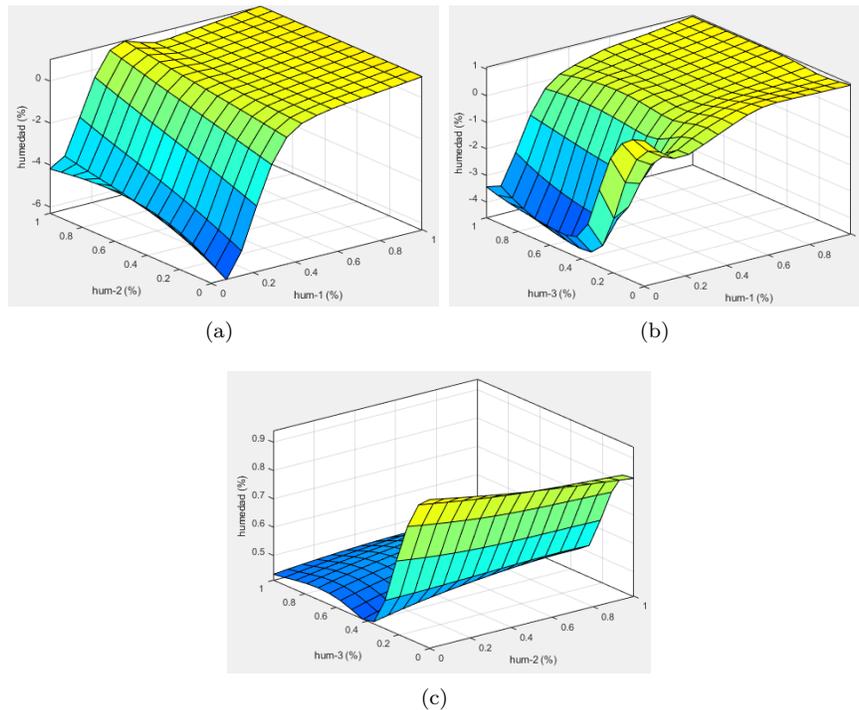


Fig. 9.7: Superficie de reglas modelo predicción basado en datos históricos: (a) superficie de reglas con un y dos desplazamientos en el tiempo; (b) superficie de reglas con un y tres desplazamientos en el tiempo; (c) superficie de reglas con dos y tres desplazamientos en el tiempo. Elaboración propia. (Entorno MATLAB®).

La estructura sistema de inferencia neurodifuso adaptativo se muestra en la Fig. 9.8, mostrando la interacción de las tres entradas con sus cinco funciones de pertenencia junto con las reglas del sistema para obtener un único valor de salida.

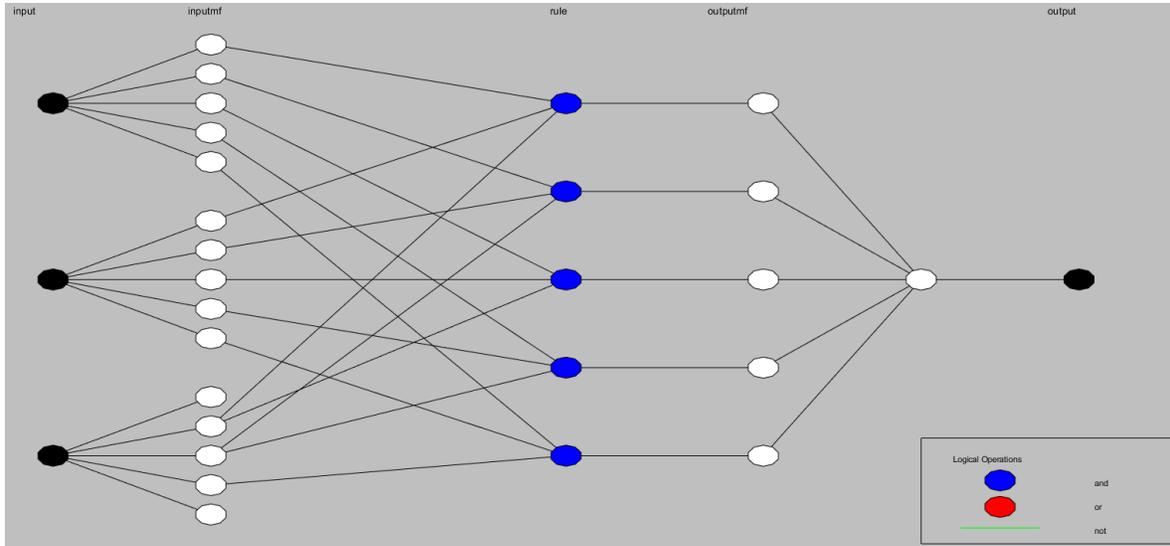


Fig. 9.8: Estructura ANFIS para modelo basado en datos históricos. Elaboración Propia. (Entorno MATLAB®).

Se realiza una prueba t de dos muestras, usando los datos reales con los generados a través del modelo planteando la hipótesis nula de que los datos provienen de muestras aleatorias independientes de distribuciones normales con medias y varianzas iguales pero con varianza desconocida. Teniendo en cuenta un $\alpha = 0,05$ la prueba arroja un $p - value = 0,9746$, y ya que el $p - value$ es mucho mayor a α , no se niega la hipótesis nula por lo cual se afirma que ambos conjuntos de datos provienen de muestras con medias y varianzas iguales, donde la prueba arroja un valor posible de varianza de 0,1419. Además teniendo en cuenta el $RMSE$ promedio de la ejecución: $1,686E - 02$, se define el porcentaje de efectividad como $(1 - RMSE) * 100$ obteniendo un valor de 98,31% para este modelo.

9.4.2. Modelo basado en variables correlacionadas

Para los modelos de predicción de humedad basados en la correlación con las variables de temperatura, concentración de CO_2 y humedad del suelo se toman la misma cantidad de datos y proporción para las fases de entrenamiento y validación que en los modelos basados en datos históricos. Se desarrollan 6 modelos usando los sistemas de inferencia difusa tipo Mamdani, Sugeno y ANFIS, y sus correspondientes con el uso de agrupamiento difuso, optimizados por el método híbrido descrito anteriormente. Para cada una de las ejecuciones aleatorias de los modelos se registran en la Tala 9.16 los valores de error máximo, mínimo, MSE, RMSE, MAE y un promedio aritmético de los MSE para las fases de entrenamiento y validación donde se resalta el modelo que presente el menor valor de MSE promedio.

Tabla 9.16: Valores de error para las ejecuciones de los modelos de predicción basados en variables correlacionadas. Elaboración Propia.

EJECUCIONES	ENTRENAMIENTO					VALIDACIÓN					\overline{MSE}	
	MSE	RMSE	MAE	MIN	MAX	MSE	RMSE	MAE	MIN	MAX		
Sugeno-Cluster	E1	1,100,E-02	1,049,E-01	1,000,E-03	0,000,E+00	4,317,E-01	1,360,E-02	1,165,E-01	1,600,E-03	0,000,E+00	3,341,E-01	1,230,E-02
	E2	1,270,E-02	1,129,E-01	1,000,E-03	0,000,E+00	4,584,E-01	8,100,E-03	9,020,E-02	1,300,E-03	0,000,E+00	2,950,E-01	1,040,E-02
	E3	1,040,E-02	1,020,E-01	9,000,E-04	0,000,E+00	4,145,E-01	2,350,E-02	1,533,E-01	2,100,E-03	0,000,E+00	3,753,E-01	1,695,E-02
	E4	1,590,E-02	1,263,E-01	1,100,E-03	0,000,E+00	4,239,E-01	4,300,E-03	6,530,E-02	9,000,E-04	1,000,E-04	1,677,E-01	1,010,E-02
	E5	1,300,E-02	1,139,E-01	1,000,E-03	0,000,E+00	4,561,E-01	1,430,E-02	1,194,E-01	1,700,E-03	4,000,E-04	2,995,E-01	1,365,E-02
	E6	1,480,E-02	1,215,E-01	1,100,E-03	0,000,E+00	4,416,E-01	1,060,E-02	1,028,E-01	1,400,E-03	0,000,E+00	2,765,E-01	1,270,E-02
	E7	1,110,E-02	1,055,E-01	1,000,E-03	0,000,E+00	3,886,E-01	3,190,E-02	1,785,E-01	2,500,E-03	0,000,E+00	4,569,E-01	2,150,E-02
	E8	1,070,E-02	1,036,E-01	9,000,E-04	0,000,E+00	4,124,E-01	1,090,E-02	1,044,E-01	1,400,E-03	0,000,E+00	3,214,E-01	1,080,E-02
	E9	1,530,E-02	1,236,E-01	1,100,E-03	0,000,E+00	4,316,E-01	4,000,E-03	6,360,E-02	9,000,E-04	0,000,E+00	2,038,E-01	9,650,E-03
	E10	1,970,E-02	1,402,E-01	1,300,E-03	0,000,E+00	4,503,E-01	4,500,E-03	6,700,E-02	9,000,E-04	0,000,E+00	1,711,E-01	1,210,E-02
	E11	9,700,E-03	9,850,E-02	9,000,E-04	0,000,E+00	4,315,E-01	1,260,E-02	1,122,E-01	1,600,E-03	0,000,E+00	3,662,E-01	1,115,E-02
	E12	1,520,E-02	1,235,E-01	1,100,E-03	0,000,E+00	4,362,E-01	6,300,E-03	7,910,E-02	1,100,E-03	0,000,E+00	2,229,E-01	1,075,E-02
	E13	1,320,E-02	1,148,E-01	1,000,E-03	0,000,E+00	3,739,E-01	5,000,E-03	7,050,E-02	1,000,E-03	0,000,E+00	1,926,E-01	9,100,E-03
	E14	1,160,E-02	1,077,E-01	1,000,E-03	0,000,E+00	4,429,E-01	1,830,E-02	1,352,E-01	1,900,E-03	0,000,E+00	3,317,E-01	1,495,E-02
	E15	1,400,E-02	1,183,E-01	1,100,E-03	0,000,E+00	4,276,E-01	5,300,E-03	7,310,E-02	1,000,E-03	1,000,E-04	1,981,E-01	9,650,E-03
	E16	1,070,E-02	1,036,E-01	9,000,E-04	0,000,E+00	4,124,E-01	1,090,E-02	1,044,E-01	1,400,E-03	0,000,E+00	3,214,E-01	1,080,E-02
	E17	1,530,E-02	1,236,E-01	1,100,E-03	0,000,E+00	4,316,E-01	4,000,E-03	6,360,E-02	9,000,E-04	0,000,E+00	2,038,E-01	9,650,E-03
	E18	1,970,E-02	1,403,E-01	1,300,E-03	0,000,E+00	4,501,E-01	4,500,E-03	6,700,E-02	9,000,E-04	0,000,E+00	1,711,E-01	1,210,E-02
	E19	1,630,E-02	1,275,E-01	1,200,E-03	0,000,E+00	4,397,E-01	3,000,E-03	5,460,E-02	8,000,E-04	0,000,E+00	2,087,E-01	9,650,E-03
	E20	2,190,E-02	1,478,E-01	1,300,E-03	1,000,E-04	4,582,E-01	5,200,E-03	7,230,E-02	1,000,E-03	1,000,E-04	1,834,E-01	1,355,E-02
	E21	1,360,E-02	1,168,E-01	1,100,E-03	0,000,E+00	4,878,E-01	1,210,E-02	1,101,E-01	1,500,E-03	1,000,E-04	3,100,E-01	1,285,E-02
	E22	1,550,E-02	1,244,E-01	1,100,E-03	0,000,E+00	4,048,E-01	3,400,E-03	5,870,E-02	8,000,E-04	0,000,E+00	1,786,E-01	9,450,E-03
	E23	1,070,E-02	1,036,E-01	9,000,E-04	0,000,E+00	4,124,E-01	1,090,E-02	1,044,E-01	1,400,E-03	0,000,E+00	3,214,E-01	1,080,E-02
	E24	1,530,E-02	1,236,E-01	1,100,E-03	0,000,E+00	4,339,E-01	4,000,E-03	6,360,E-02	9,000,E-04	0,000,E+00	2,036,E-01	9,650,E-03
	E25	2,170,E-02	1,474,E-01	1,300,E-03	0,000,E+00	5,521,E-01	5,400,E-03	7,350,E-02	1,000,E-03	1,000,E-04	2,030,E-01	1,355,E-02
	E26	1,590,E-02	1,263,E-01	1,100,E-03	0,000,E+00	4,141,E-01	4,400,E-03	6,610,E-02	9,000,E-04	1,000,E-04	1,844,E-01	1,015,E-02
	E27	1,320,E-02	1,147,E-01	1,000,E-03	0,000,E+00	4,252,E-01	1,080,E-02	1,039,E-01	1,400,E-03	0,000,E+00	2,698,E-01	1,200,E-02
	E28	1,770,E-02	1,331,E-01	1,200,E-03	0,000,E+00	4,012,E-01	3,700,E-03	6,060,E-02	8,000,E-04	0,000,E+00	1,871,E-01	1,070,E-02
	E29	3,120,E-02	1,768,E-01	1,600,E-03	1,000,E-04	7,802,E-01	1,450,E-02	1,204,E-01	1,700,E-03	1,000,E-04	3,917,E-01	2,285,E-02
	E30	1,290,E-02	1,136,E-01	1,000,E-03	0,000,E+00	4,138,E-01	2,280,E-02	1,511,E-01	2,100,E-03	0,000,E+00	3,323,E-01	1,785,E-02
	E1	6,100,E-03	7,790,E-02	7,000,E-04	0,000,E+00	6,470,E-01	1,050,E-02	1,027,E-01	1,400,E-03	0,000,E+00	4,111,E-01	8,300,E-03
	E2	5,600,E-03	7,460,E-02	7,000,E-04	0,000,E+00	4,342,E-01	1,680,E-02	1,298,E-01	1,800,E-03	0,000,E+00	4,751,E-01	1,120,E-02
	E3	6,100,E-03	7,790,E-02	7,000,E-04	0,000,E+00	4,315,E-01	1,870,E-02	1,368,E-01	1,900,E-03	0,000,E+00	4,372,E-01	1,240,E-02
	E4	6,100,E-03	7,790,E-02	7,000,E-04	0,000,E+00	3,998,E-01	1,100,E-02	1,049,E-01	1,500,E-03	0,000,E+00	4,178,E-01	8,550,E-03
	E5	5,900,E-03	7,660,E-02	7,000,E-04	0,000,E+00	4,452,E-01	1,100,E-02	1,049,E-01	1,500,E-03	0,000,E+00	3,883,E-01	8,450,E-03
	E6	4,600,E-03	6,790,E-02	6,000,E-04	0,000,E+00	4,256,E-01	7,900,E-03	8,900,E-02	1,200,E-03	0,000,E+00	2,911,E-01	6,250,E-03
	E7	5,800,E-03	7,600,E-02	7,000,E-04	0,000,E+00	4,272,E-01	7,800,E-03	8,830,E-02	1,200,E-03	0,000,E+00	3,416,E-01	6,800,E-03
	E8	5,600,E-03	7,500,E-02	7,000,E-04	0,000,E+00	4,336,E-01	1,160,E-02	1,078,E-01	1,500,E-03	1,000,E-04	7,310,E-01	8,600,E-03
	E9	6,300,E-03	7,970,E-02	7,000,E-04	0,000,E+00	3,821,E-01	1,260,E-02	1,124,E-01	1,600,E-03	1,000,E-04	2,833,E-01	9,450,E-03
	E10	7,000,E-03	8,380,E-02	8,000,E-04	0,000,E+00	4,151,E-01	1,200,E-02	1,095,E-01	1,500,E-03	0,000,E+00	4,375,E-01	9,500,E-03

Tabla 9.16 Valores de error para las ejecuciones de los modelos de predicción basados en variables correlacionadas. Elaboración Propia.

EJECUCIONES		ENTRENAMIENTO					VALIDACIÓN					\overline{MSE}
		MSE	RMSE	MAE	MIN	MAX	MSE	RMSE	MAE	MIN	MAX	
ANFIS-Cluster	E11	5,200,E-03	7,220,E-02	7,000,E-04	0,000,E+00	4,385,E-01	4,540,E-02	2,130,E-01	3,000,E-03	0,000,E+00	8,493,E-01	2,530,E-02
	E12	5,700,E-03	7,520,E-02	7,000,E-04	0,000,E+00	4,056,E-01	1,410,E-02	1,189,E-01	1,700,E-03	0,000,E+00	2,603,E-01	9,900,E-03
	E13	6,000,E-03	7,760,E-02	7,000,E-04	0,000,E+00	4,095,E-01	6,500,E-03	8,090,E-02	1,100,E-03	0,000,E+00	3,411,E-01	6,250,E-03
	E14	5,700,E-03	7,560,E-02	7,000,E-04	0,000,E+00	4,278,E-01	1,340,E-02	1,156,E-01	1,600,E-03	0,000,E+00	4,251,E-01	9,550,E-03
	E15	5,900,E-03	7,700,E-02	7,000,E-04	0,000,E+00	4,005,E-01	1,420,E-02	1,193,E-01	1,700,E-03	0,000,E+00	3,434,E-01	1,005,E-02
	E16	5,600,E-03	7,500,E-02	7,000,E-04	0,000,E+00	4,336,E-01	1,160,E-02	1,078,E-01	1,500,E-03	1,000,E-04	7,310,E-01	8,600,E-03
	E17	6,300,E-03	7,970,E-02	7,000,E-04	0,000,E+00	3,821,E-01	1,260,E-02	1,124,E-01	1,600,E-03	1,000,E-04	2,833,E-01	9,450,E-03
	E18	9,000,E-03	9,490,E-02	9,000,E-04	0,000,E+00	3,945,E-01	1,580,E-02	1,257,E-01	1,700,E-03	1,000,E-04	7,014,E-01	1,240,E-02
	E19	7,200,E-03	8,490,E-02	8,000,E-04	0,000,E+00	5,573,E-01	1,520,E-02	1,233,E-01	1,700,E-03	0,000,E+00	3,020,E-01	1,120,E-02
	E20	1,130,E-02	1,064,E-01	1,000,E-03	0,000,E+00	6,001,E-01	2,200,E-02	1,482,E-01	2,100,E-03	0,000,E+00	8,480,E-01	1,665,E-02
	E21	6,600,E-03	8,120,E-02	7,000,E-04	0,000,E+00	4,247,E-01	1,250,E-02	1,119,E-01	1,600,E-03	0,000,E+00	3,823,E-01	9,550,E-03
	E22	4,800,E-03	6,900,E-02	6,000,E-04	0,000,E+00	4,267,E-01	1,010,E-02	1,005,E-01	1,400,E-03	0,000,E+00	5,780,E-01	7,450,E-03
	E23	5,600,E-03	7,500,E-02	7,000,E-04	0,000,E+00	4,336,E-01	1,160,E-02	1,078,E-01	1,500,E-03	1,000,E-04	7,310,E-01	8,600,E-03
	E24	6,300,E-03	7,970,E-02	7,000,E-04	0,000,E+00	3,821,E-01	1,260,E-02	1,124,E-01	1,600,E-03	1,000,E-04	2,833,E-01	9,450,E-03
	E25	6,700,E-03	8,160,E-02	7,000,E-04	0,000,E+00	4,835,E-01	1,310,E-02	1,144,E-01	1,600,E-03	0,000,E+00	4,612,E-01	9,900,E-03
	E26	5,200,E-03	7,220,E-02	7,000,E-04	0,000,E+00	4,213,E-01	4,300,E-03	6,570,E-02	9,000,E-04	0,000,E+00	3,418,E-01	4,750,E-03
	E27	6,400,E-03	8,000,E-02	7,000,E-04	0,000,E+00	4,291,E-01	9,400,E-03	9,670,E-02	1,300,E-03	0,000,E+00	4,154,E-01	7,900,E-03
	E28	6,000,E-03	7,720,E-02	7,000,E-04	0,000,E+00	4,082,E-01	1,120,E-02	1,060,E-01	1,500,E-03	0,000,E+00	4,952,E-01	8,600,E-03
	E29	6,700,E-03	8,200,E-02	7,000,E-04	0,000,E+00	4,291,E-01	8,400,E-03	9,150,E-02	1,300,E-03	0,000,E+00	3,695,E-01	7,550,E-03
	E30	5,800,E-03	7,610,E-02	7,000,E-04	0,000,E+00	4,731,E-01	4,900,E-03	6,980,E-02	1,000,E-03	0,000,E+00	3,455,E-01	5,350,E-03
Mamdani-Cluster	E1	1,390,E-02	1,180,E-01	1,100,E-03	0,000,E+00	3,823,E-01	8,800,E-03	9,370,E-02	1,300,E-03	2,000,E-04	2,321,E-01	1,135,E-02
	E2	1,440,E-02	1,201,E-01	1,100,E-03	0,000,E+00	4,019,E-01	7,300,E-03	8,570,E-02	1,200,E-03	0,000,E+00	2,874,E-01	1,085,E-02
	E3	1,250,E-02	1,116,E-01	1,000,E-03	0,000,E+00	4,105,E-01	8,500,E-03	9,220,E-02	1,300,E-03	4,000,E-04	2,874,E-01	1,050,E-02
	E4	1,210,E-02	1,102,E-01	1,000,E-03	0,000,E+00	4,316,E-01	5,800,E-03	7,610,E-02	1,100,E-03	2,000,E-04	2,218,E-01	8,950,E-03
	E5	1,300,E-02	1,139,E-01	1,000,E-03	1,000,E-04	4,158,E-01	5,700,E-03	7,550,E-02	1,000,E-03	0,000,E+00	2,263,E-01	9,350,E-03
	E6	1,580,E-02	1,256,E-01	1,100,E-03	0,000,E+00	3,907,E-01	7,400,E-03	8,620,E-02	1,200,E-03	6,000,E-04	2,934,E-01	1,160,E-02
	E7	1,230,E-02	1,107,E-01	1,000,E-03	0,000,E+00	4,668,E-01	6,300,E-03	7,950,E-02	1,100,E-03	0,000,E+00	2,711,E-01	9,300,E-03
	E8	1,260,E-02	1,123,E-01	1,000,E-03	0,000,E+00	4,215,E-01	6,100,E-03	7,800,E-02	1,100,E-03	0,000,E+00	2,048,E-01	9,350,E-03
	E9	1,210,E-02	1,100,E-01	1,000,E-03	0,000,E+00	4,349,E-01	7,500,E-03	8,630,E-02	1,200,E-03	0,000,E+00	2,355,E-01	9,800,E-03
	E10	1,210,E-02	1,100,E-01	1,000,E-03	0,000,E+00	4,328,E-01	7,600,E-03	8,700,E-02	1,200,E-03	0,000,E+00	2,874,E-01	9,850,E-03
	E11	1,670,E-02	1,293,E-01	1,200,E-03	0,000,E+00	3,843,E-01	6,600,E-03	8,150,E-02	1,100,E-03	1,000,E-04	2,299,E-01	1,165,E-02
	E12	1,190,E-02	1,089,E-01	1,000,E-03	0,000,E+00	4,239,E-01	5,000,E-03	7,090,E-02	1,000,E-03	0,000,E+00	2,756,E-01	8,450,E-03
	E13	1,190,E-02	1,092,E-01	1,000,E-03	0,000,E+00	4,119,E-01	8,200,E-03	9,060,E-02	1,300,E-03	0,000,E+00	2,551,E-01	1,005,E-02
	E14	1,210,E-02	1,099,E-01	1,000,E-03	0,000,E+00	4,222,E-01	7,100,E-03	8,400,E-02	1,200,E-03	0,000,E+00	2,716,E-01	9,600,E-03
	E15	1,180,E-02	1,087,E-01	1,000,E-03	0,000,E+00	4,321,E-01	7,700,E-03	8,760,E-02	1,200,E-03	0,000,E+00	2,423,E-01	9,750,E-03
	E16	1,470,E-02	1,213,E-01	1,100,E-03	0,000,E+00	4,006,E-01	5,700,E-03	7,540,E-02	1,000,E-03	1,000,E-04	2,299,E-01	1,020,E-02
	E17	1,310,E-02	1,146,E-01	1,000,E-03	0,000,E+00	4,185,E-01	5,900,E-03	7,650,E-02	1,100,E-03	0,000,E+00	2,180,E-01	9,500,E-03
	E18	1,200,E-02	1,096,E-01	1,000,E-03	0,000,E+00	4,345,E-01	7,400,E-03	8,590,E-02	1,200,E-03	1,000,E-04	2,389,E-01	9,700,E-03
	E19	1,230,E-02	1,108,E-01	1,000,E-03	0,000,E+00	4,190,E-01	7,400,E-03	8,600,E-02	1,200,E-03	0,000,E+00	2,812,E-01	9,850,E-03
	E20	1,170,E-02	1,081,E-01	1,000,E-03	0,000,E+00	4,263,E-01	8,300,E-03	9,090,E-02	1,300,E-03	0,000,E+00	2,874,E-01	1,000,E-02
	E21	1,220,E-02	1,105,E-01	1,000,E-03	0,000,E+00	4,260,E-01	7,000,E-03	8,370,E-02	1,200,E-03	0,000,E+00	2,556,E-01	9,600,E-03
	E22	1,300,E-02	1,140,E-01	1,000,E-03	0,000,E+00	4,176,E-01	5,800,E-03	7,650,E-02	1,100,E-03	0,000,E+00	2,263,E-01	9,400,E-03

Tabla 9.16 Valores de error para las ejecuciones de los modelos de predicción basados en variables correlacionadas. Elaboración Propia.

EJECUCIONES		ENTRENAMIENTO					VALIDACIÓN					\overline{MSE}
		MSE	RMSE	MAE	MIN	MAX	MSE	RMSE	MAE	MIN	MAX	
	E23	1,240,E-02	1,115,E-01	1,000,E-03	0,000,E+00	4,181,E-01	7,200,E-03	8,500,E-02	1,200,E-03	0,000,E+00	2,767,E-01	9,800,E-03
	E24	1,300,E-02	1,139,E-01	1,000,E-03	0,000,E+00	4,134,E-01	5,600,E-03	7,490,E-02	1,000,E-03	0,000,E+00	2,263,E-01	9,300,E-03
	E25	1,210,E-02	1,098,E-01	1,000,E-03	0,000,E+00	4,345,E-01	6,000,E-03	7,780,E-02	1,100,E-03	3,000,E-04	2,934,E-01	9,050,E-03
	E26	1,490,E-02	1,221,E-01	1,100,E-03	0,000,E+00	4,049,E-01	5,400,E-03	7,350,E-02	1,000,E-03	1,000,E-04	2,299,E-01	1,015,E-02
	E27	1,220,E-02	1,104,E-01	1,000,E-03	0,000,E+00	4,263,E-01	6,900,E-03	8,320,E-02	1,200,E-03	0,000,E+00	2,268,E-01	9,550,E-03
	E28	1,190,E-02	1,089,E-01	1,000,E-03	0,000,E+00	4,286,E-01	8,000,E-03	8,970,E-02	1,200,E-03	0,000,E+00	2,874,E-01	9,950,E-03
	E29	1,220,E-02	1,107,E-01	1,000,E-03	0,000,E+00	4,325,E-01	5,400,E-03	7,360,E-02	1,000,E-03	0,000,E+00	2,874,E-01	8,800,E-03
	E30	1,220,E-02	1,103,E-01	1,000,E-03	0,000,E+00	3,906,E-01	6,200,E-03	7,850,E-02	1,100,E-03	0,000,E+00	2,934,E-01	9,200,E-03
	E1	1,440,E-02	1,199,E-01	1,100,E-03	1,000,E-04	5,404,E-01	5,600,E-03	7,480,E-02	1,000,E-03	0,000,E+00	4,038,E-01	1,000,E-02
	E2	1,410,E-02	1,185,E-01	1,100,E-03	0,000,E+00	7,422,E-01	7,300,E-03	8,540,E-02	1,200,E-03	1,000,E-04	4,235,E-01	1,070,E-02
	E3	3,710,E-02	1,926,E-01	1,700,E-03	0,000,E+00	8,781,E-01	3,300,E-02	1,817,E-01	2,500,E-03	1,000,E-04	4,450,E-01	3,505,E-02
	E4	1,380,E-02	1,177,E-01	1,100,E-03	0,000,E+00	7,526,E-01	7,400,E-03	8,570,E-02	1,200,E-03	0,000,E+00	3,190,E-01	1,060,E-02
	E5	2,630,E-02	1,621,E-01	1,500,E-03	1,000,E-04	6,490,E-01	2,380,E-02	1,544,E-01	2,100,E-03	2,000,E-04	2,735,E-01	2,505,E-02
	E6	2,190,E-02	1,480,E-01	1,300,E-03	0,000,E+00	5,430,E-01	1,600,E-02	1,263,E-01	1,800,E-03	0,000,E+00	2,630,E-01	1,895,E-02
	E7	2,270,E-02	1,505,E-01	1,400,E-03	0,000,E+00	4,939,E-01	1,150,E-02	1,073,E-01	1,500,E-03	2,000,E-04	2,760,E-01	1,710,E-02
	E8	1,440,E-02	1,199,E-01	1,100,E-03	1,000,E-04	5,404,E-01	5,600,E-03	7,480,E-02	1,000,E-03	0,000,E+00	4,038,E-01	1,000,E-02
	E9	1,410,E-02	1,185,E-01	1,100,E-03	0,000,E+00	7,422,E-01	7,300,E-03	8,540,E-02	1,200,E-03	1,000,E-04	4,235,E-01	1,070,E-02
	E10	3,710,E-02	1,926,E-01	1,700,E-03	0,000,E+00	8,781,E-01	3,300,E-02	1,817,E-01	2,500,E-03	1,000,E-04	4,450,E-01	3,505,E-02
	E11	1,380,E-02	1,177,E-01	1,100,E-03	0,000,E+00	7,526,E-01	7,400,E-03	8,570,E-02	1,200,E-03	0,000,E+00	3,190,E-01	1,060,E-02
	E12	2,630,E-02	1,621,E-01	1,500,E-03	1,000,E-04	6,490,E-01	2,380,E-02	1,544,E-01	2,100,E-03	2,000,E-04	2,735,E-01	2,505,E-02
	E13	2,190,E-02	1,480,E-01	1,300,E-03	0,000,E+00	5,430,E-01	1,600,E-02	1,263,E-01	1,800,E-03	0,000,E+00	2,630,E-01	1,895,E-02
	E14	1,590,E-02	1,260,E-01	1,100,E-03	0,000,E+00	4,849,E-01	3,400,E-03	5,840,E-02	8,000,E-04	0,000,E+00	3,523,E-01	9,650,E-03
	E15	2,440,E-02	1,563,E-01	1,400,E-03	0,000,E+00	1,025,E+00	1,370,E-02	1,171,E-01	1,600,E-03	0,000,E+00	3,429,E-01	1,905,E-02
	E16	1,440,E-02	1,199,E-01	1,100,E-03	1,000,E-04	5,404,E-01	5,600,E-03	7,480,E-02	1,000,E-03	0,000,E+00	4,038,E-01	1,000,E-02
	E17	1,410,E-02	1,185,E-01	1,100,E-03	0,000,E+00	7,422,E-01	7,300,E-03	8,540,E-02	1,200,E-03	1,000,E-04	4,235,E-01	1,070,E-02
	E18	3,710,E-02	1,926,E-01	1,700,E-03	0,000,E+00	8,781,E-01	3,300,E-02	1,817,E-01	2,500,E-03	1,000,E-04	4,450,E-01	3,505,E-02
	E19	1,370,E-02	1,173,E-01	1,100,E-03	0,000,E+00	8,274,E-01	6,600,E-03	8,150,E-02	1,100,E-03	3,000,E-04	2,699,E-01	1,015,E-02
	E20	1,320,E-02	1,147,E-01	1,000,E-03	0,000,E+00	6,574,E-01	1,100,E-02	1,049,E-01	1,500,E-03	1,000,E-04	2,720,E-01	1,210,E-02
	E21	1,310,E-02	1,146,E-01	1,000,E-03	0,000,E+00	7,139,E-01	5,700,E-03	7,520,E-02	1,000,E-03	1,000,E-04	3,258,E-01	9,400,E-03
	E22	3,330,E-02	1,825,E-01	1,700,E-03	0,000,E+00	7,276,E-01	4,300,E-02	2,074,E-01	2,900,E-03	1,000,E-04	4,596,E-01	3,815,E-02
	E23	1,600,E-02	1,267,E-01	1,200,E-03	0,000,E+00	5,921,E-01	3,000,E-03	5,470,E-02	8,000,E-04	0,000,E+00	2,554,E-01	9,500,E-03
	E24	1,420,E-02	1,190,E-01	1,100,E-03	0,000,E+00	6,453,E-01	5,300,E-03	7,290,E-02	1,000,E-03	0,000,E+00	3,736,E-01	9,750,E-03
	E25	1,450,E-02	1,203,E-01	1,100,E-03	0,000,E+00	7,968,E-01	7,700,E-03	8,800,E-02	1,200,E-03	0,000,E+00	3,432,E-01	1,110,E-02
	E26	3,140,E-02	1,772,E-01	1,600,E-03	0,000,E+00	7,730,E-01	3,050,E-02	1,748,E-01	2,400,E-03	0,000,E+00	3,733,E-01	3,095,E-02
	E27	3,230,E-02	1,797,E-01	1,600,E-03	0,000,E+00	8,779,E-01	3,600,E-02	1,896,E-01	2,600,E-03	2,000,E-04	4,436,E-01	3,415,E-02
	E28	2,020,E-02	1,422,E-01	1,300,E-03	0,000,E+00	6,508,E-01	9,800,E-03	9,900,E-02	1,400,E-03	2,000,E-04	2,504,E-01	1,500,E-02
	E29	1,270,E-02	1,128,E-01	1,000,E-03	0,000,E+00	5,114,E-01	2,320,E-02	1,522,E-01	2,100,E-03	0,000,E+00	5,471,E-01	1,795,E-02
	E30	2,230,E-02	1,495,E-01	1,400,E-03	0,000,E+00	1,533,E+00	1,450,E-02	1,202,E-01	1,700,E-03	3,000,E-04	2,531,E-01	1,840,E-02
	E1	5,800,E-03	7,630,E-02	7,000,E-04	0,000,E+00	4,805,E-01	9,600,E-03	9,790,E-02	1,400,E-03	0,000,E+00	4,916,E-01	7,700,E-03
	E2	6,300,E-03	7,930,E-02	7,000,E-04	0,000,E+00	4,233,E-01	1,460,E-02	1,209,E-01	1,700,E-03	0,000,E+00	4,356,E-01	1,045,E-02
	E3	6,600,E-03	8,140,E-02	7,000,E-04	0,000,E+00	4,779,E-01	1,050,E-02	1,025,E-01	1,400,E-03	1,000,E-04	3,850,E-01	8,550,E-03
	E4	5,900,E-03	7,710,E-02	7,000,E-04	0,000,E+00	4,204,E-01	9,200,E-03	9,600,E-02	1,300,E-03	0,000,E+00	3,447,E-01	7,550,E-03

Tabla 9.16 Valores de error para las ejecuciones de los modelos de predicción basados en variables correlacionadas. Elaboración Propia.

EJECUCIONES		ENTRENAMIENTO					VALIDACIÓN					\overline{MSE}	
		MSE	RMSE	MAE	MIN	MAX	MSE	RMSE	MAE	MIN	MAX		
ANFIS	E5	5,900,E-03	7,670,E-02	7,000,E-04	0,000,E+00	4,267,E-01	2,060,E-02	1,437,E-01	2,000,E-03	0,000,E+00	4,528,E-01	1,325,E-02	
	E6	6,200,E-03	7,900,E-02	7,000,E-04	0,000,E+00	4,602,E-01	1,630,E-02	1,276,E-01	1,800,E-03	1,000,E-04	4,401,E-01	1,125,E-02	
	E7	7,700,E-03	8,750,E-02	8,000,E-04	0,000,E+00	6,428,E-01	1,040,E-02	1,020,E-01	1,400,E-03	0,000,E+00	1,973,E+00	9,050,E-03	
	E8	5,800,E-03	7,630,E-02	7,000,E-04	0,000,E+00	4,805,E-01	9,600,E-03	9,790,E-02	1,400,E-03	0,000,E+00	4,916,E-01	7,700,E-03	
	E9	6,300,E-03	7,930,E-02	7,000,E-04	0,000,E+00	4,233,E-01	1,460,E-02	1,209,E-01	1,700,E-03	0,000,E+00	4,356,E-01	1,045,E-02	
	E10	6,600,E-03	8,140,E-02	7,000,E-04	0,000,E+00	4,779,E-01	1,050,E-02	1,025,E-01	1,400,E-03	1,000,E-04	3,850,E-01	8,550,E-03	
	E11	5,900,E-03	7,710,E-02	7,000,E-04	0,000,E+00	4,204,E-01	9,200,E-03	9,600,E-02	1,300,E-03	0,000,E+00	3,447,E-01	7,550,E-03	
	E12	5,900,E-03	7,670,E-02	7,000,E-04	0,000,E+00	4,267,E-01	2,060,E-02	1,437,E-01	2,000,E-03	0,000,E+00	4,528,E-01	1,325,E-02	
	E13	6,200,E-03	7,900,E-02	7,000,E-04	0,000,E+00	4,602,E-01	1,630,E-02	1,276,E-01	1,800,E-03	1,000,E-04	4,401,E-01	1,125,E-02	
	E14	6,100,E-03	7,800,E-02	7,000,E-04	0,000,E+00	3,892,E-01	1,210,E-02	1,098,E-01	1,500,E-03	0,000,E+00	5,189,E-01	9,100,E-03	
	E15	7,400,E-03	8,570,E-02	8,000,E-04	0,000,E+00	4,765,E-01	1,030,E-02	1,016,E-01	1,400,E-03	0,000,E+00	3,246,E-01	8,850,E-03	
	E16	5,800,E-03	7,630,E-02	7,000,E-04	0,000,E+00	4,805,E-01	9,600,E-03	9,790,E-02	1,400,E-03	0,000,E+00	4,916,E-01	7,700,E-03	
	E17	6,300,E-03	7,930,E-02	7,000,E-04	0,000,E+00	4,233,E-01	1,460,E-02	1,209,E-01	1,700,E-03	0,000,E+00	4,356,E-01	1,045,E-02	
	E18	6,600,E-03	8,140,E-02	7,000,E-04	0,000,E+00	4,779,E-01	1,050,E-02	1,025,E-01	1,400,E-03	1,000,E-04	3,850,E-01	8,550,E-03	
	E19	5,700,E-03	7,540,E-02	7,000,E-04	0,000,E+00	5,253,E-01	1,350,E-02	1,163,E-01	1,600,E-03	0,000,E+00	3,970,E-01	9,600,E-03	
	E20	6,000,E-03	7,720,E-02	7,000,E-04	0,000,E+00	4,289,E-01	4,400,E-03	6,630,E-02	9,000,E-04	0,000,E+00	4,331,E-01	5,200,E-03	
	E21	5,800,E-03	7,640,E-02	7,000,E-04	0,000,E+00	4,796,E-01	1,300,E-02	1,141,E-01	1,600,E-03	0,000,E+00	3,546,E-01	9,400,E-03	
	E22	6,400,E-03	8,030,E-02	7,000,E-04	0,000,E+00	4,255,E-01	9,400,E-03	9,710,E-02	1,300,E-03	0,000,E+00	4,152,E-01	7,900,E-03	
	E23	5,900,E-03	7,680,E-02	7,000,E-04	0,000,E+00	4,113,E-01	1,600,E-02	1,265,E-01	1,800,E-03	0,000,E+00	3,894,E-01	1,095,E-02	
	E24	5,100,E-03	7,150,E-02	6,000,E-04	0,000,E+00	4,074,E-01	8,700,E-03	9,340,E-02	1,300,E-03	0,000,E+00	3,482,E-01	6,900,E-03	
	E25	6,000,E-03	7,770,E-02	7,000,E-04	0,000,E+00	4,473,E-01	2,520,E-02	1,587,E-01	2,200,E-03	0,000,E+00	1,022,E+00	1,560,E-02	
	E26	6,800,E-03	8,220,E-02	7,000,E-04	0,000,E+00	7,388,E-01	1,060,E-02	1,029,E-01	1,400,E-03	0,000,E+00	6,182,E-01	8,700,E-03	
	E27	7,300,E-03	8,530,E-02	8,000,E-04	0,000,E+00	4,120,E-01	1,290,E-02	1,134,E-01	1,600,E-03	0,000,E+00	5,387,E-01	1,010,E-02	
	E28	6,200,E-03	7,900,E-02	7,000,E-04	0,000,E+00	5,990,E-01	1,410,E-02	1,186,E-01	1,600,E-03	1,000,E-04	4,475,E-01	1,015,E-02	
	E29	6,000,E-03	7,720,E-02	7,000,E-04	0,000,E+00	6,191,E-01	8,900,E-03	9,460,E-02	1,300,E-03	0,000,E+00	7,285,E-01	7,450,E-03	
	E30	6,400,E-03	7,990,E-02	7,000,E-04	0,000,E+00	7,983,E-01	8,400,E-03	9,180,E-02	1,300,E-03	0,000,E+00	3,319,E-01	7,400,E-03	
	Mamdani	E1	1,260,E-02	1,121,E-01	1,000,E-03	1,000,E-04	4,457,E-01	5,900,E-03	7,710,E-02	1,100,E-03	0,000,E+00	2,925,E-01	9,250,E-03
		E2	1,020,E-02	1,008,E-01	9,000,E-04	4,000,E-04	4,474,E-01	1,060,E-02	1,032,E-01	1,400,E-03	1,000,E-04	4,095,E-01	1,040,E-02
		E3	1,060,E-02	1,032,E-01	9,000,E-04	0,000,E+00	4,760,E-01	8,900,E-03	9,440,E-02	1,300,E-03	2,000,E-04	3,095,E-01	9,750,E-03
		E4	1,130,E-02	1,065,E-01	1,000,E-03	0,000,E+00	4,353,E-01	9,300,E-03	9,640,E-02	1,300,E-03	1,000,E-04	3,226,E-01	1,030,E-02
E5		9,300,E-03	9,630,E-02	9,000,E-04	1,000,E-04	5,068,E-01	7,100,E-03	8,430,E-02	1,200,E-03	0,000,E+00	2,516,E-01	8,200,E-03	
E6		1,080,E-02	1,038,E-01	9,000,E-04	0,000,E+00	5,431,E-01	3,730,E-02	1,932,E-01	2,700,E-03	2,000,E-04	5,414,E-01	2,405,E-02	
E7		1,010,E-02	1,004,E-01	9,000,E-04	0,000,E+00	4,932,E-01	7,600,E-03	8,700,E-02	1,200,E-03	2,000,E-04	3,735,E-01	8,850,E-03	
E8		1,260,E-02	1,121,E-01	1,000,E-03	1,000,E-04	4,457,E-01	5,900,E-03	7,710,E-02	1,100,E-03	0,000,E+00	2,925,E-01	9,250,E-03	
E9		1,020,E-02	1,008,E-01	9,000,E-04	4,000,E-04	4,474,E-01	1,060,E-02	1,032,E-01	1,400,E-03	1,000,E-04	4,095,E-01	1,040,E-02	
E10		1,060,E-02	1,032,E-01	9,000,E-04	0,000,E+00	4,760,E-01	8,900,E-03	9,440,E-02	1,300,E-03	2,000,E-04	3,095,E-01	9,750,E-03	
E11		1,130,E-02	1,065,E-01	1,000,E-03	0,000,E+00	4,353,E-01	9,300,E-03	9,640,E-02	1,300,E-03	1,000,E-04	3,226,E-01	1,030,E-02	
E12		9,300,E-03	9,630,E-02	9,000,E-04	1,000,E-04	5,068,E-01	7,100,E-03	8,430,E-02	1,200,E-03	0,000,E+00	2,516,E-01	8,200,E-03	
E13		1,080,E-02	1,038,E-01	9,000,E-04	0,000,E+00	5,431,E-01	3,730,E-02	1,932,E-01	2,700,E-03	2,000,E-04	5,414,E-01	2,405,E-02	
E14		1,010,E-02	1,004,E-01	9,000,E-04	0,000,E+00	4,932,E-01	7,600,E-03	8,700,E-02	1,200,E-03	2,000,E-04	3,735,E-01	8,850,E-03	
E15		1,060,E-02	1,030,E-01	9,000,E-04	1,000,E-04	4,650,E-01	9,900,E-03	9,950,E-02	1,400,E-03	2,000,E-04	4,870,E-01	1,025,E-02	
E16		1,260,E-02	1,121,E-01	1,000,E-03	1,000,E-04	4,457,E-01	5,900,E-03	7,710,E-02	1,100,E-03	0,000,E+00	2,925,E-01	9,250,E-03	

Tabla 9.16 Valores de error para las ejecuciones de los modelos de predicción basados en variables correlacionadas. Elaboración Propia.

EJECUCIONES	ENTRENAMIENTO					VALIDACIÓN					\overline{MSE}
	MSE	RMSE	MAE	MIN	MAX	MSE	RMSE	MAE	MIN	MAX	
E17	1,020,E-02	1,008,E-01	9,000,E-04	3,000,E-04	4,474,E-01	1,070,E-02	1,033,E-01	1,400,E-03	1,000,E-04	4,095,E-01	1,045,E-02
E18	1,090,E-02	1,042,E-01	9,000,E-04	0,000,E+00	4,405,E-01	9,200,E-03	9,570,E-02	1,300,E-03	3,000,E-04	4,044,E-01	1,005,E-02
E19	1,080,E-02	1,037,E-01	9,000,E-04	1,000,E-04	4,450,E-01	9,500,E-03	9,730,E-02	1,400,E-03	1,000,E-04	3,174,E-01	1,015,E-02
E20	1,160,E-02	1,077,E-01	1,000,E-03	0,000,E+00	6,269,E-01	8,600,E-03	9,260,E-02	1,300,E-03	2,000,E-04	4,455,E-01	1,010,E-02
E21	9,900,E-03	9,950,E-02	9,000,E-04	0,000,E+00	4,951,E-01	8,900,E-03	9,430,E-02	1,300,E-03	2,000,E-04	5,101,E-01	9,400,E-03
E22	1,000,E-02	1,002,E-01	9,000,E-04	0,000,E+00	4,415,E-01	9,900,E-03	9,940,E-02	1,400,E-03	1,000,E-04	3,294,E-01	9,950,E-03
E23	1,260,E-02	1,121,E-01	1,000,E-03	1,000,E-04	4,457,E-01	5,900,E-03	7,710,E-02	1,100,E-03	0,000,E+00	2,925,E-01	9,250,E-03
E24	1,020,E-02	1,008,E-01	9,000,E-04	4,000,E-04	4,474,E-01	1,060,E-02	1,032,E-01	1,400,E-03	1,000,E-04	4,095,E-01	1,040,E-02
E25	1,060,E-02	1,032,E-01	9,000,E-04	0,000,E+00	4,760,E-01	8,900,E-03	9,440,E-02	1,300,E-03	2,000,E-04	3,095,E-01	9,750,E-03
E26	1,130,E-02	1,065,E-01	1,000,E-03	0,000,E+00	4,353,E-01	9,300,E-03	9,640,E-02	1,300,E-03	1,000,E-04	3,226,E-01	1,030,E-02
E27	9,300,E-03	9,630,E-02	9,000,E-04	1,000,E-04	5,068,E-01	7,100,E-03	8,430,E-02	1,200,E-03	0,000,E+00	2,516,E-01	8,200,E-03
E28	1,080,E-02	1,038,E-01	9,000,E-04	0,000,E+00	5,431,E-01	3,730,E-02	1,932,E-01	2,700,E-03	2,000,E-04	5,414,E-01	2,405,E-02
E29	1,010,E-02	1,004,E-01	9,000,E-04	0,000,E+00	4,932,E-01	7,600,E-03	8,700,E-02	1,200,E-03	2,000,E-04	3,735,E-01	8,850,E-03
E30	1,060,E-02	1,030,E-01	9,000,E-04	1,000,E-04	4,650,E-01	9,900,E-03	9,950,E-02	1,400,E-03	2,000,E-04	4,870,E-01	1,025,E-02

Teniendo en cuenta los valores obtenidos se muestran los promedios aritméticos de los valores de error para los 6 modelos propuestos en la Tabla 9.17, donde se observa que los errores más bajos están presentes en el modelo tipo ANFIS.

Tabla 9.17: Valores promedio de error para las ejecuciones de los modelos de predicción basados en variables correlacionadas. Elaboración Propia.

SISTEMA DE INFERENCIA DIFUSA	ENTRENAMIENTO					VALIDACIÓN				
	MSE	RMSE	MAE	MIN	MAX	MSE	RMSE	MAE	MIN	MAX
Sugeno-Cluster	1,500,E-02	1,213,E-01	1,090,E-03	6,667,E-06	4,446,E-01	9,760,E-03	9,351,E-02	1,293,E-03	3,667,E-05	2,628,E-01
ANFIS-Cluster	6,237,E-03	7,866,E-02	7,167,E-04	0	4,401,E-01	1,296,E-02	1,109,E-01	1,550,E-03	2,333,E-05	4,567,E-01
Mamdani-Cluster	1,284,E-02	1,132,E-01	1,023,E-03	3,333,E-06	4,185,E-01	6,793,E-03	8,220,E-02	1,147,E-03	7,000,E-05	2,560,E-01
Sugeno	2,069,E-02	1,413,E-01	1,283,E-03	1,667,E-05	7,227,E-01	1,523,E-02	1,154,E-01	1,597,E-03	8,333,E-05	3,555,E-01
ANFIS	6,230,E-03	7,889,E-02	7,067,E-04	0	4,854,E-01	1,247,E-02	1,102,E-01	1,530,E-03	2,000,E-05	5,084,E-01
Mamdani	1,073,E-02	1,035,E-01	9,267,E-04	8,333,E-05	4,772,E-01	1,142,E-02	1,022,E-01	1,420,E-03	1,267,E-04	3,728,E-01

Según los datos de la Tabla 9.16 se relaciona a continuación el modelo implementado junto con la ejecución que presenta el mejor nivel de precisión.

- Sugeno con agrupamiento difuso, ejecución 13 con un MSE promedio de 9,100 E-03 en entrenamiento y validación.
- ANFIS con agrupamiento difuso, ejecución 26 con un MSE promedio de 4,750 E-03 en entrenamiento y validación.
- Mamdani con agrupamiento difuso, ejecución 12 con un MSE promedio de 8,450 E-03 en entrenamiento y validación.
- Sugeno, ejecución 21 con un MSE promedio de 9,400 E-03 en entrenamiento y validación.
- ANFIS, ejecución 20 con un MSE promedio de 5,200 E-03 en entrenamiento y validación.
- Mamdani, ejecución 5, 12 o 27 con un MSE promedio de 8,200 E-03 en entrenamiento y validación.

Los valores obtenidos en la fase de entrenamiento a partir de la predicción de cada uno de los modelos respecto a los reales se muestran en la Fig. 9.9 relacionando en las abscisas el periodo de tiempo entre el 24 de mayo hasta el 22 de julio de 2021 y en las ordenadas los valores de humedad relativa en porcentaje (%).

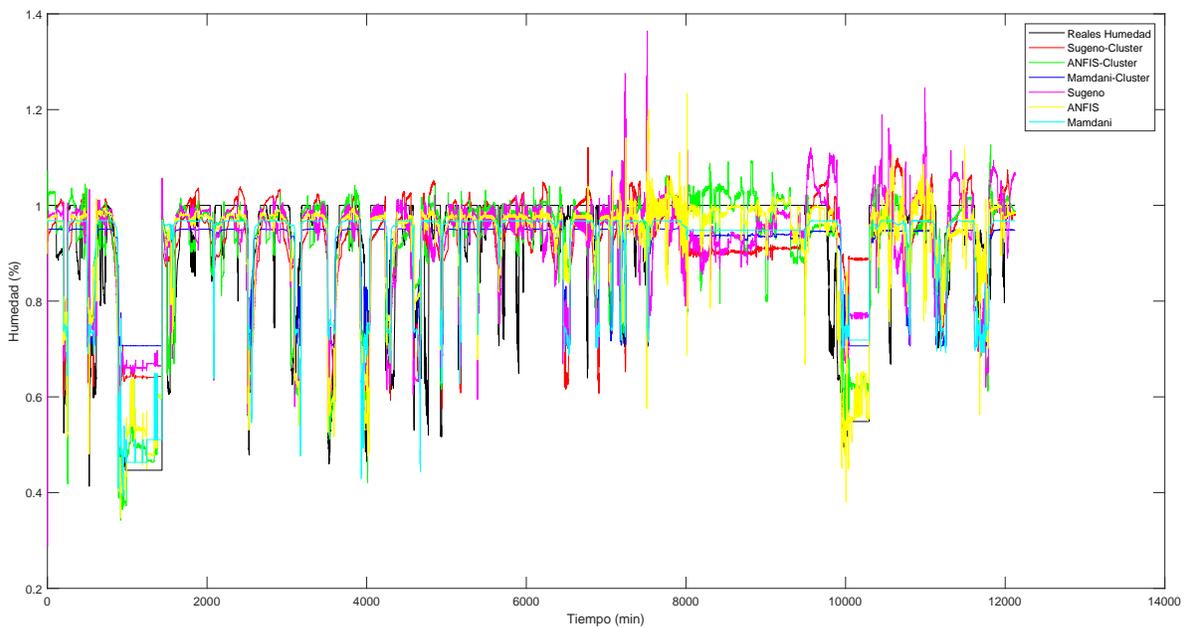


Fig. 9.9: Comparación valores reales y de los modelos basados en variables correlacionadas en la fase de entrenamiento. Elaboración Propia. (Entorno MATLAB®).

La comparación de los valores obtenidos de la predicción de los modelos y los reales para la fase

de validación se muestra en la Fig. 9.10 obteniendo resultados homogéneos en cada modelo con gran precisión.

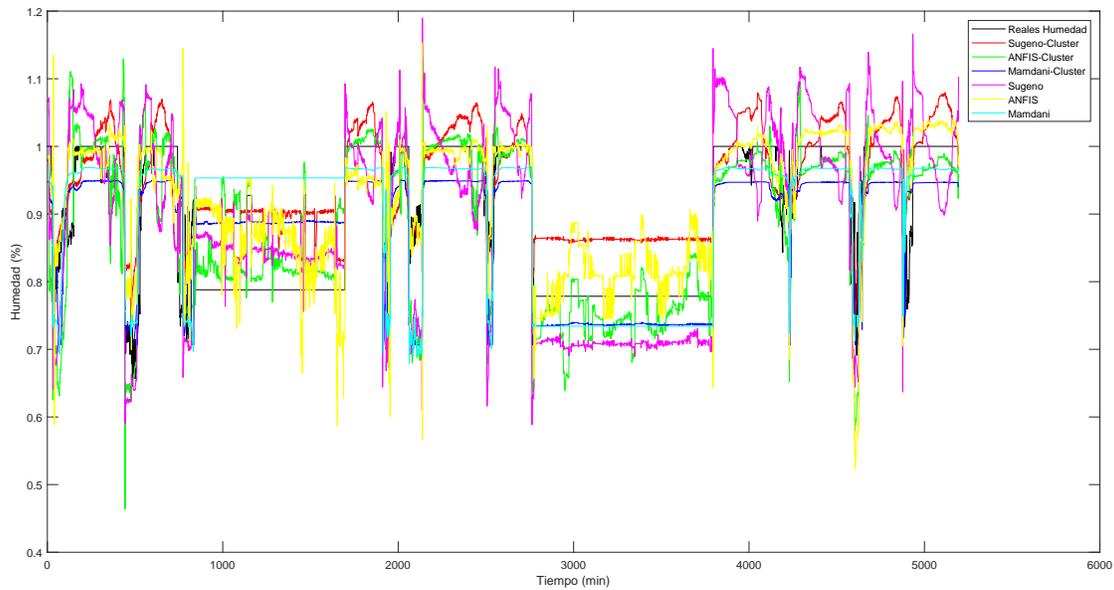


Fig. 9.10: Comparación valores reales y de los modelos basados en variables correlacionadas en la fase de validación. Elaboración Propia. (Entorno MATLAB®).

Teniendo en cuenta los MSE obtenidos en cada uno de los modelos se muestra en la Fig. 9.11 la relación del error entre los datos de humedad obtenidos de los modelos y los reales en el periodo de tiempo analizado, donde el eje de las abscisas corresponde al tiempo y el de las ordenadas al error.

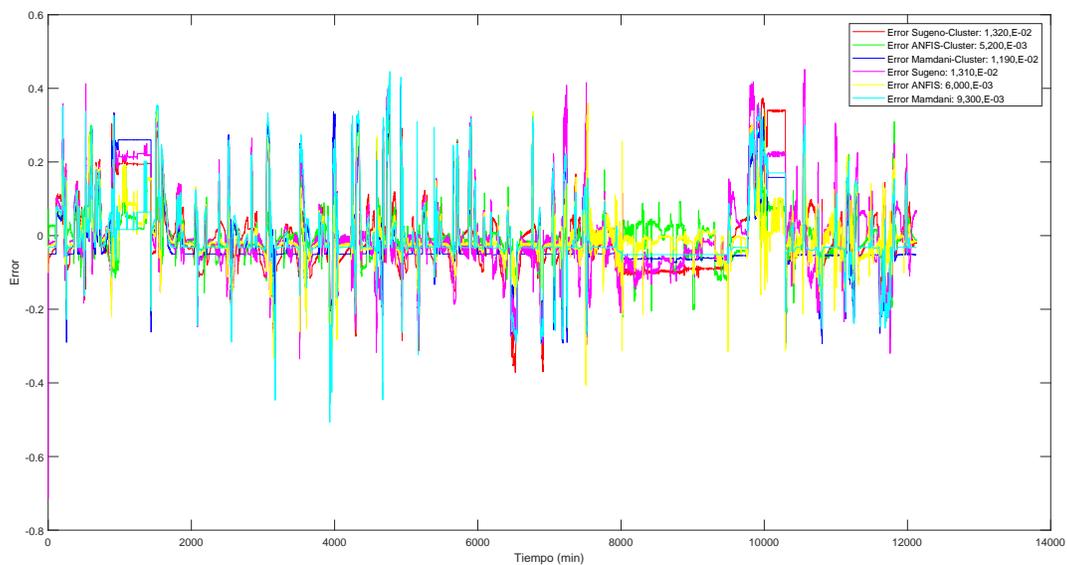


Fig. 9.11: Error valores reales con los de los modelos basados en variables correlacionadas en la fase de entrenamiento. Elaboración Propia. (Entorno MATLAB®).

De igual manera la Fig. 9.12 muestra la relación de error para los datos de humedad obtenidos de la predicción y los reales a través del tiempo.

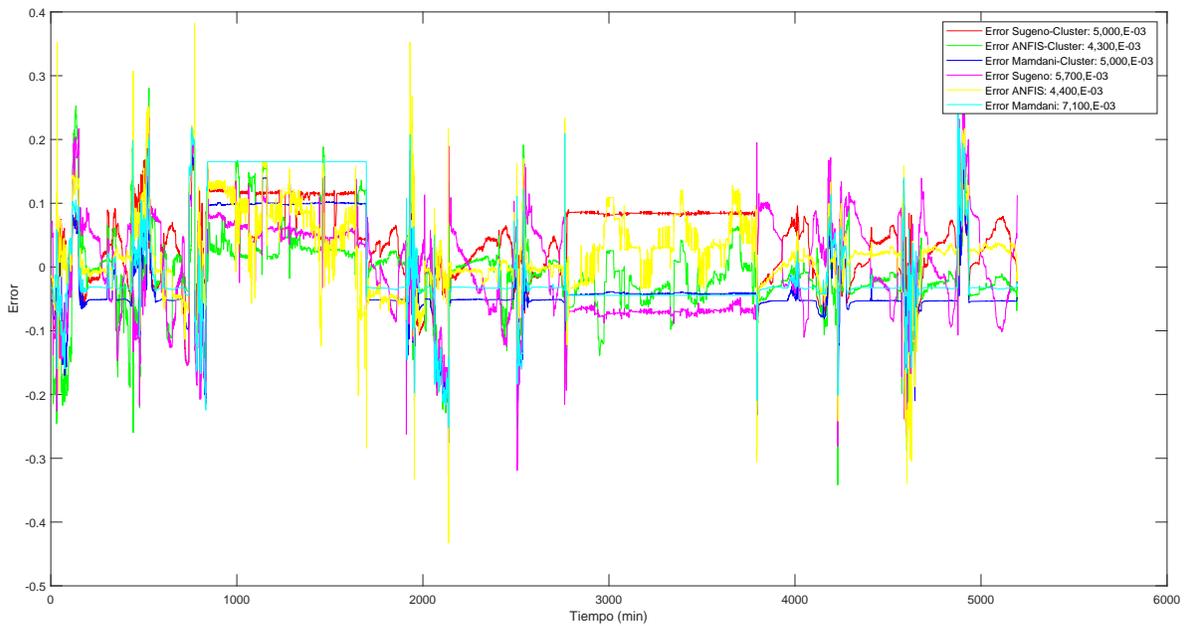


Fig. 9.12: Error valores reales con los de los modelos basados en variables correlacionadas en la fase de validación. Elaboración Propia. (Entorno MATLAB®).

Teniendo en cuenta los resultados de la Tabla 9.16, se muestra el análisis de precisión e interpretabilidad para los modelos en la Tabla 9.18 donde se relaciona el grado de precisión e interpretabilidad para cada modelo.

Tabla 9.18: Análisis de precisión e interpretabilidad para modelos basados en variables correlacionadas. Elaboración Propia.

SISTEMA DE INFERENCIA DIFUSA	MEJOR MSE	\overline{MSE}	PRECISIÓN	INTERPRETACIÓN	RANKING
Sugeno-Cluster	9,100,E-03	1,238,E-02	2,0	3,0	5,0
ANFIS-Cluster	4,750,E-03	9,598,E-03	5,5	1,0	6,5
Mamdani-Cluster	8,450,E-03	9,815,E-03	3,5	5,0	8,5
Sugeno	9,400,E-03	1,796,E-02	1,0	4,0	5,0
ANFIS	5,200,E-03	9,352,E-03	5,5	2,0	7,5
Mamdani	8,200,E-03	1,108,E-02	3,5	6,0	9,5

Modelo implementado en el prototipo software

El modelo que se selecciona para predicción de humedad relativa basada en temperatura, concentración de CO_2 y humedad del suelo es la ejecución 5 del sistema de inferencia difusa tipo Mamdani optimizado por método híbrido usando algoritmo genético y algoritmo de punto interior. El sistema de inferencia para la temperatura se muestra en la Fig. 9.13, donde el conjunto de entrada de valor de temperatura actual corresponde a la Fig. 9.13(a), los del primer desplazamiento a la Fig. 9.13(b) y los del segundo desplazamiento a la Fig. 9.13(c).

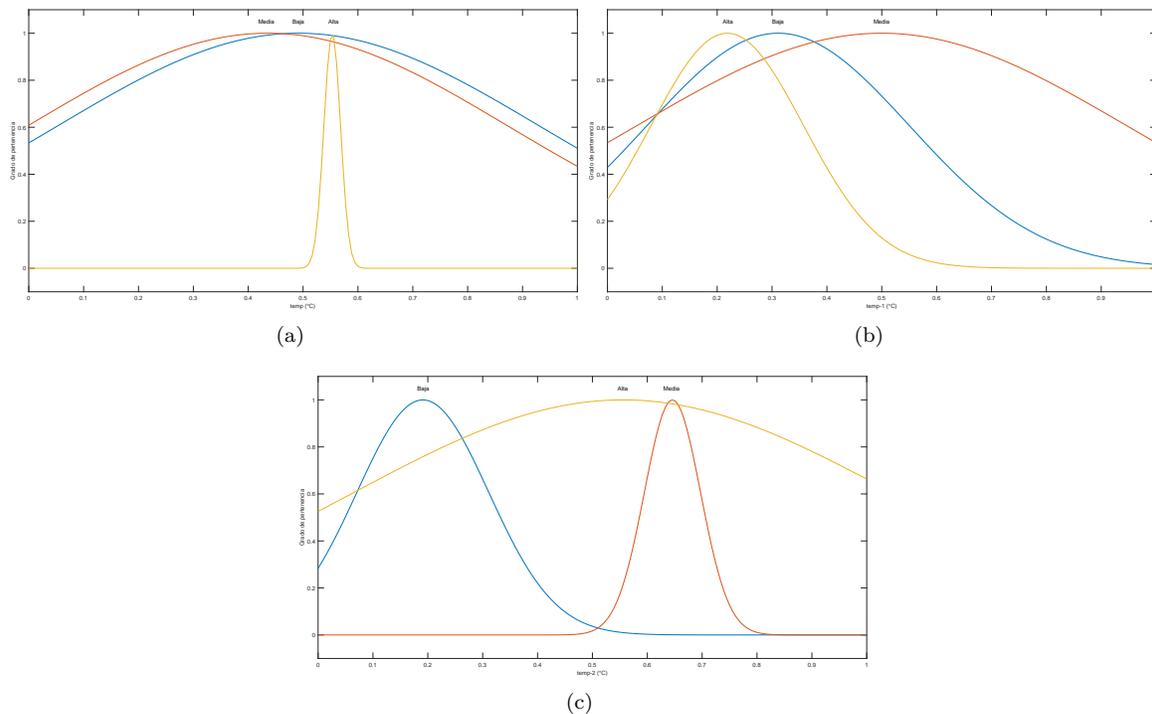


Fig. 9.13: Conjuntos difusos temperatura modelo predicción basado en variables correlacionadas: (a) conjunto difuso en el instante actual; (b) conjunto difuso con un desplazamiento en el tiempo; (c) conjunto difuso con dos desplazamientos en el tiempo. Elaboración propia. (Entorno MATLAB®).

El sistema de inferencia para la concentración de CO_2 se muestra en la Fig. 9.14, donde el conjunto de entrada de valor de concentración de CO_2 actual corresponde a la Fig. 9.14(a), los del primer desplazamiento a la Fig. 9.14(b) y los del segundo desplazamiento a la Fig. 9.14(c).

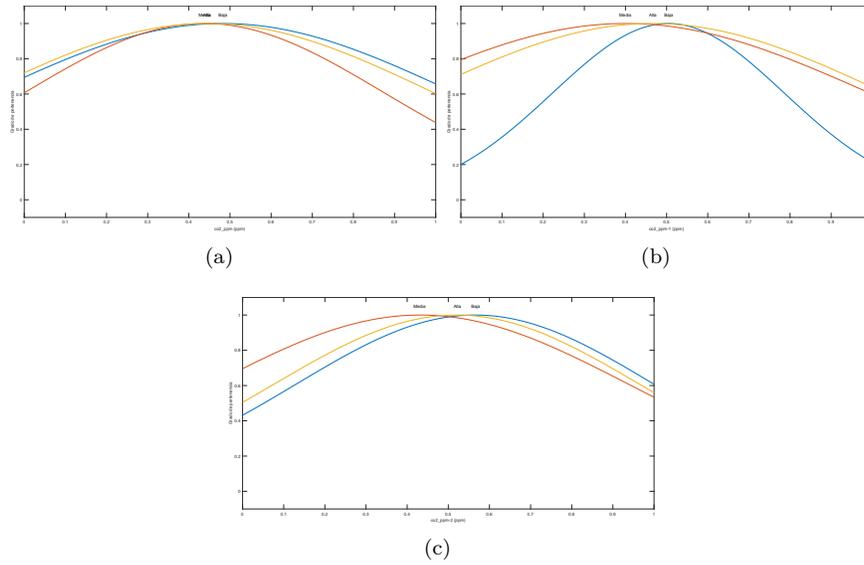


Fig. 9.14: Conjuntos difusos concentración de CO_2 modelo predicción basado en variables correlacionadas: (a) conjunto difuso en el instante actual; (b) conjunto difuso con un desplazamiento en el tiempo; (c) conjunto difuso con dos desplazamientos en el tiempo. Elaboración propia. (Entorno MATLAB®).

El sistema de inferencia para la humedad del suelo se muestra en la Fig. 9.15, donde el conjunto de entrada de valor de humedad del suelo actual corresponde a la Fig. 9.15(a), los del primer desplazamiento a la Fig. 9.15(b) y los del segundo desplazamiento a la Fig. 9.15(c).

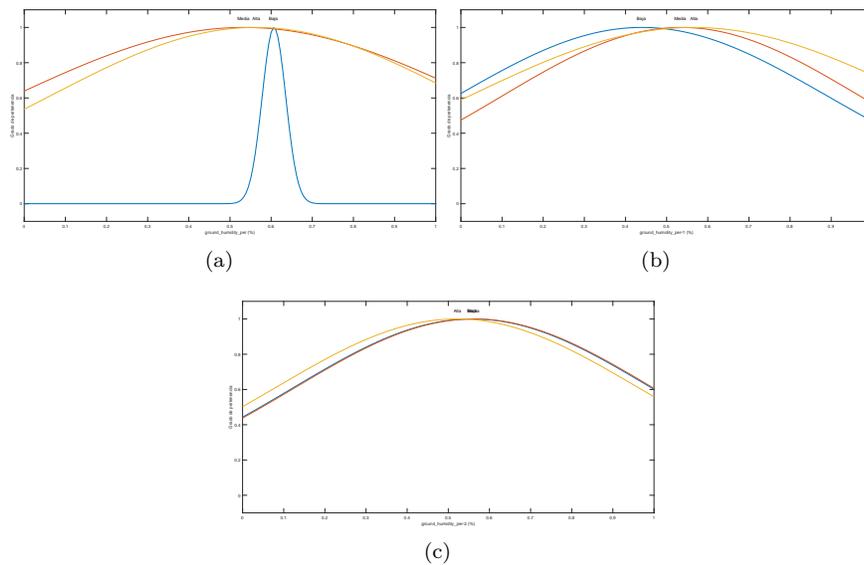


Fig. 9.15: Conjuntos difusos humedad del suelo modelo predicción basado en variables correlacionadas: (a) conjunto difuso en el instante actual; (b) conjunto difuso con un desplazamiento en el tiempo; (c) conjunto difuso con dos desplazamientos en el tiempo. Elaboración propia. (Entorno MATLAB®).

El sistema de inferencia difusa de salida para la humedad relativa interna se muestra en la Fig. 9.16, donde se mantienen las estructuras iniciales de las entradas muy bajo, bajo, medio, alto y muy alto, ajustados los valores de sus funciones de pertenencia.

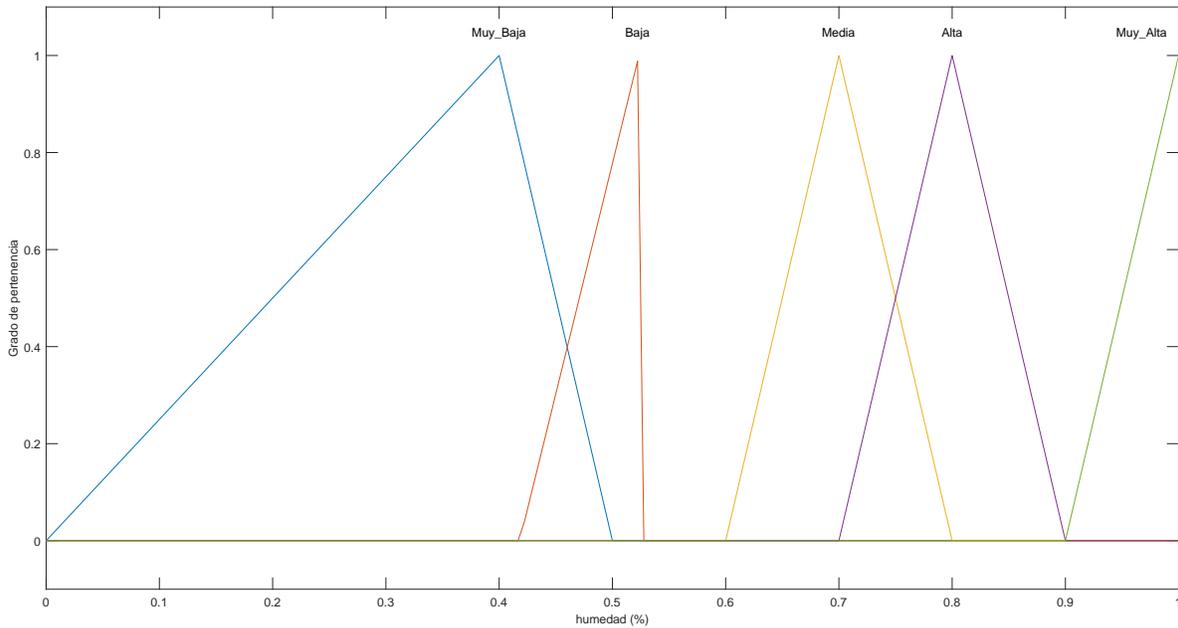


Fig. 9.16: Conjuntos difusos humedad relativa interna modelo predicción basado en variables correlacionadas. Elaboración Propia. (Entorno MATLAB®).

Las reglas definidas y su interacción con los conjuntos difusos de entrada y salida se muestra en la Fig. 9.17, donde se muestran comportamientos homogéneos en la mayoría de las entradas a excepción de temp-2 y gorund_humidity_per.

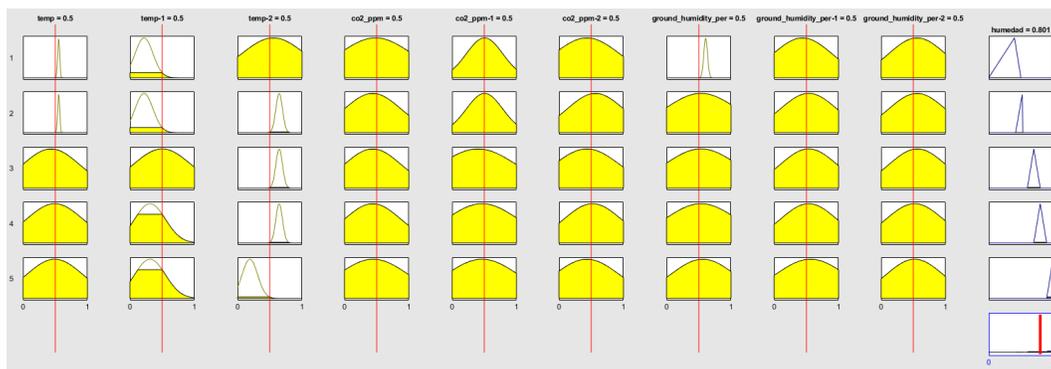


Fig. 9.17: Reglas del sistema de inferencia para modelo basado en variables correlacionadas. Elaboración Propia. (Entorno MATLAB®).

La superficie de reglas que refleja el comportamiento de las reglas a través del espacio muestral

para las variables de entrada y salida se muestra en la Fig. 9.18, donde al ser un espacio de diez dimensiones, se especifican las tres componentes en los instantes actuales donde se muestra para la variable de salida la superficie formada por las entradas temp y co2_ppm en la Fig. 9.18(a), temp y ground_humidity_per en la Fig. 9.18(b) y co2_ppm y ground_humidity_per en la Fig. 9.18(c).

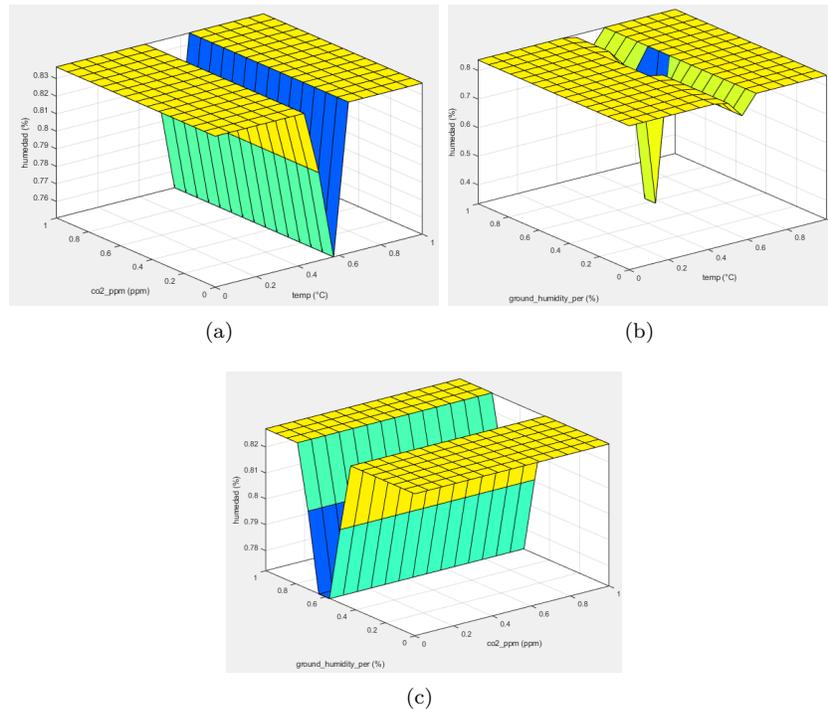


Fig. 9.18: Superficie de reglas modelo predicción basado en datos históricos: (a) superficie de reglas con un y dos desplazamientos en el tiempo; (b) superficie de reglas con un y tres desplazamientos en el tiempo; (c) superficie de reglas con dos y tres desplazamientos en el tiempo. Elaboración propia. (Entorno MATLAB®).

Se realiza una prueba t de dos muestras, usando los datos reales con los generados a través del modelo, teniendo en cuenta un $\alpha = 0,05$ la prueba arroja un $p - value = 0,1740$, y ya que el $p - value$ es mayor a α , no se niega la hipótesis nula por lo cual se afirma que ambas provienen de muestras con medias y varianzas iguales, donde la prueba arroja un valor posible de varianza de $0,1301$. Adicionalmente teniendo en cuenta el $RMSE$ promedio de la ejecución: $9,030E - 02$, se obtiene el porcentaje de efectividad con un valor de $90,97\%$ para este modelo.

9.5. PROTOTIPO SOFTWARE

Teniendo en cuenta los modelos de predicción seleccionados, se almacena el sistema de inferencia difusa y su configuración para dos tipos de modelos: basados en datos históricos y basados en variables correlacionadas. Dependiendo del tipo de modelo y basado en un archivo con los datos de las variables de entrada, se elabora un prototipo software que permite visualizar de manera gráfica la predicción de humedad relativa desde estos dos enfoques.

9.5.1. Funcionamiento del prototipo

El funcionamiento del prototipo sigue el flujo de selección de modelo y posterior carga de datos, los datos utilizados deben estar en formato csv, permitiendo ser importados desde cualquier entorno que sea compatible, como un formulario web o directamente de un microcontrolador, el archivo de datos debe contener en cada registro los siguientes datos en este orden para cada una de las columnas:

- Modelo basado en datos históricos de humedad
 1. Humedad con un desplazamiento en el tiempo.
 2. Humedad con dos desplazamientos en el tiempo.
 3. Humedad con tres desplazamientos en el tiempo.
- Modelo basado en variables correlacionadas
 1. Temperatura interna actual.
 2. Temperatura interna con un desplazamiento en el tiempo.
 3. Temperatura interna con dos desplazamientos en el tiempo.
 4. Concentración de CO_2 actual.
 5. Concentración de CO_2 con un desplazamiento en el tiempo.
 6. Concentración de CO_2 con dos desplazamientos en el tiempo.
 7. Humedad del suelo actual.
 8. Humedad del suelo con un desplazamiento en el tiempo.
 9. Humedad del suelo con dos desplazamientos en el tiempo.

Al abrir el aplicativo se encontrara un menú de cuatro opciones en la zona superior: “Predicción numérica”, “Interpretación modelos correlación”, “Interpretación modelos históricos” y “Acerca de nosotros”, en la opción “Predicción numérica”, en la parte superior se seleccionara el modelo que se usara ya sea el basado en datos históricos o en variables correlacionadas, al escoger alguno se habilitara la opción de carga del archivo de datos segun corresponda, al dar clic a esta opción como se muestra en la Fig. 9.19, se desplegara el explorador de archivos donde seleccionaremos el archivo con los datos.

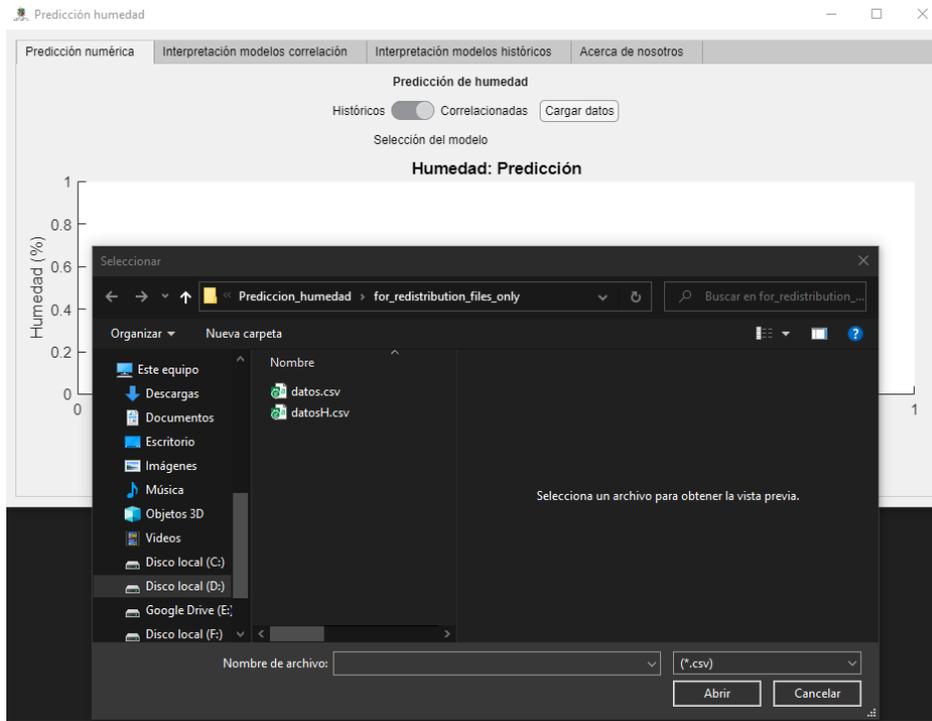


Fig. 9.19: Carga de datos. Elaboración propia. (Entorno MATLAB®)

Al cargar el archivo con los datos se realizara la predicción de la humedad relativa interna para cada registro como se muestra en la Fig. 9.20, donde en la parte inferior de manera gráfica se desplegara la predicción acompañada del error de predicción del modelo utilizado.

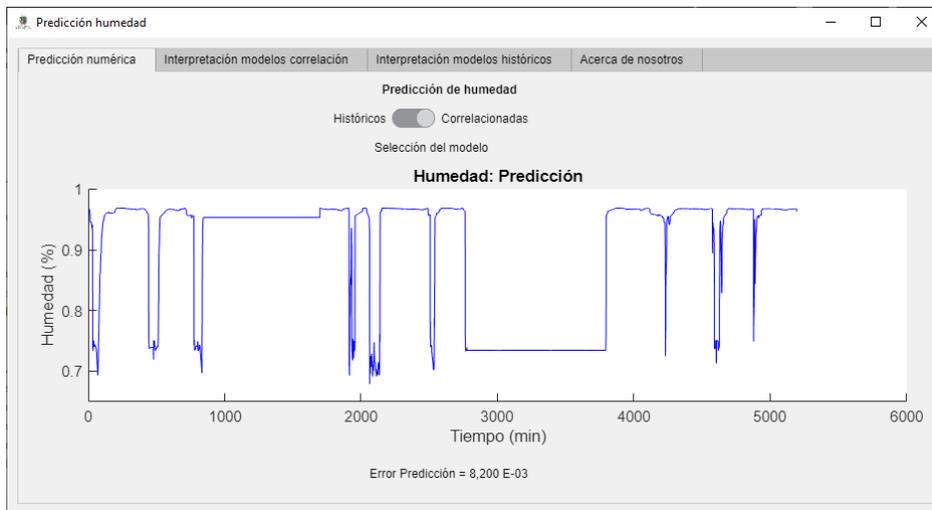


Fig. 9.20: Prototipo de visualización, predicción de humedad interna en invernaderos. Elaboración propia. (Entorno MATLAB®)

La interpretación de los resultados se muestra en las opciones “Interpretación modelos correlación” e “Interpretación modelos históricos”, como se evidencia en la Fig. 9.21, donde al hacer clic en los botones denominados “Conjunto difuso”, se desplegará la representación gráfica del conjunto en una nueva ventana con sus respectivas funciones de pertinencia.

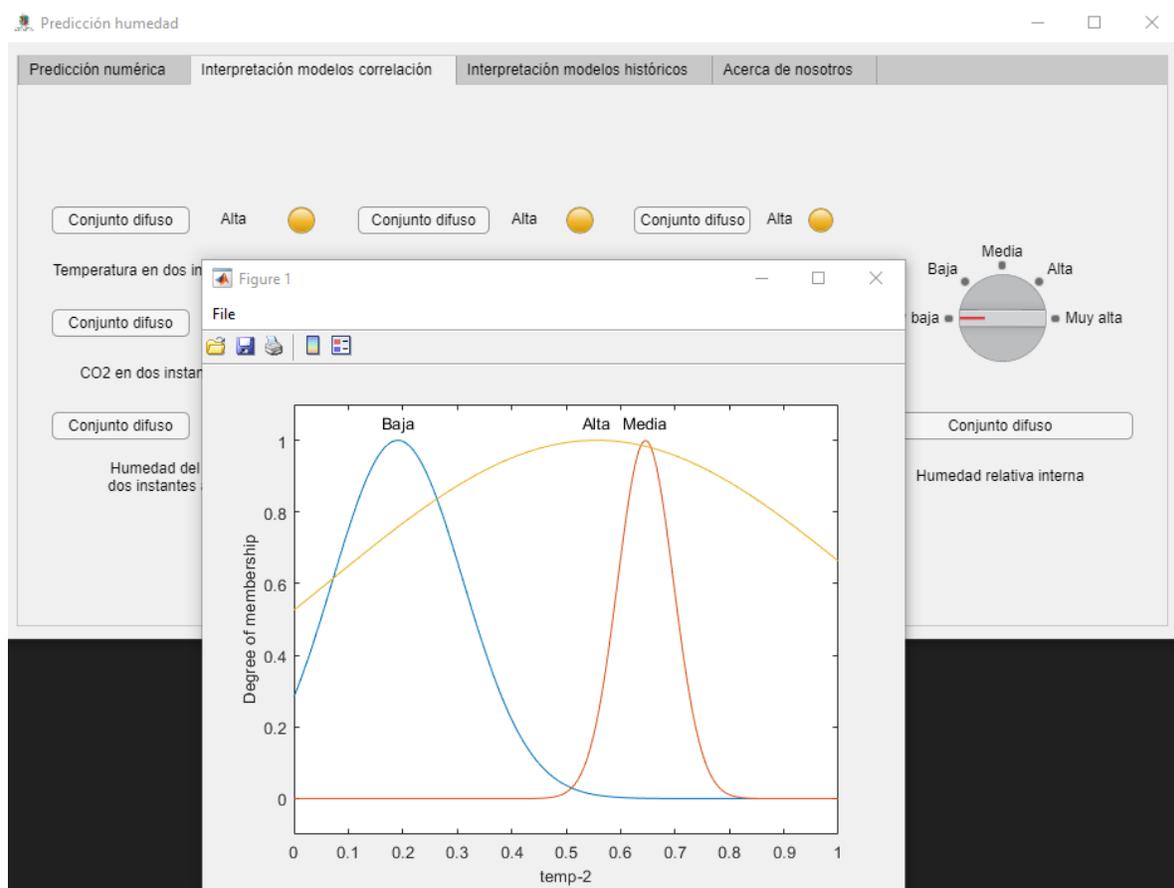


Fig. 9.21: Prototipo de visualización, conjuntos difusos. Elaboración propia. (Entorno MATLAB®)

Por otra parte en el sector derecho, como se muestra en la Fig. 9.22, se encuentra un dial con las opciones cualitativas para la humedad interna, con el cual se mostrará el comportamiento de las entradas según las reglas del sistema de inferencia difuso, indicando el valor de la función de pertenencia y su color, según la representación de la Fig. 9.21, que se obtiene según el valor cualitativo designado en la predicción.



Fig. 9.22: Prototipo de visualización, reglas de inferencia. Elaboración propia. (Entorno MATLAB®)

9.5.2. Despliegue del prototipo

El prototipo se desarrolla con características de usabilidad y portabilidad, es por ello que se muestran dos opciones de despliegue, detalladas en esta sección, una aplicación de escritorio y una aplicación web.

Aplicación de escritorio

El prototipo de visualización mostrado en la Fig. 9.23, se desplegará como un ejecutable “Prediccion_humedad.exe”, acompañado de: una imagen de icono “splash.png”, un archivo con los requisitos para su ejecución “readme.txt” y el archivo que contiene los dos conjuntos de datos de prueba utilizados, “datos.csv” para el modelo basado en variables correlacionadas y “datosH.csv” para el basado en datos históricos de humedad relativa.

Nombre	Tipo	Tamaño
datos.csv	Archivo de valores separados por comas de Microsoft Excel	836 KB
datosH.csv	Archivo de valores separados por comas de Microsoft Excel	170 KB
Prediccion_humedad.exe	Aplicación	3.580 KB
readme.txt	Documento de texto	2 KB
splash.png	Archivo PNG	47 KB

Fig. 9.23: Repositorio de despliegue prototipo de visualización. Elaboración propia.

Si no se dispone de los requisitos de Runtime de Matlab, se incluirá un archivo denominado “MyAppInstaller_web.exe”, que permitirá instalar el entorno de ejecución del aplicativo.

Aplicación Web

Para acceder a la aplicación web se accederá a la url del servidor, implementada en el Centro de Computación de Alto Desempeño (CECAD) de la Universidad Distrital Francisco José de Caldas. El menú principal se muestra en la Fig. 9.24, donde se ven los detalles de la aplicación: nombre, autores, descripción y versión del aplicativo.

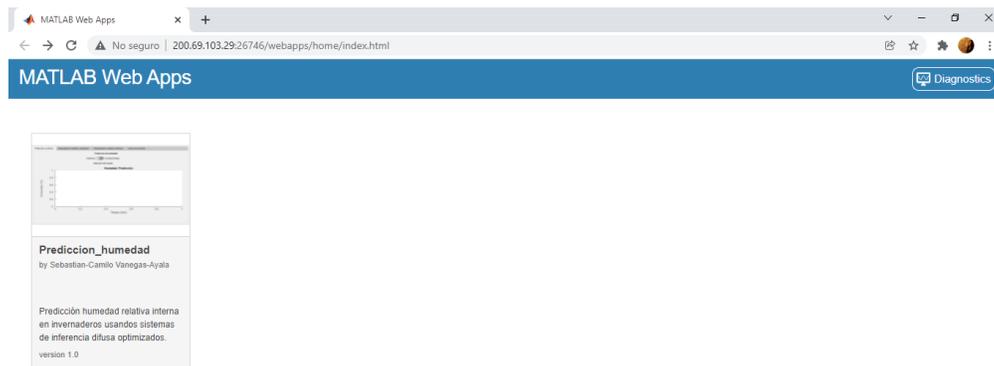


Fig. 9.24: Servidor de aplicaciones Web. Elaboración propia. (Entorno MATLAB®)

Al entrar en el aplicativo, como se muestra en la Fig. 9.25, se abre la interfaz principal, con opciones de re-dimensión y log de acciones y errores.

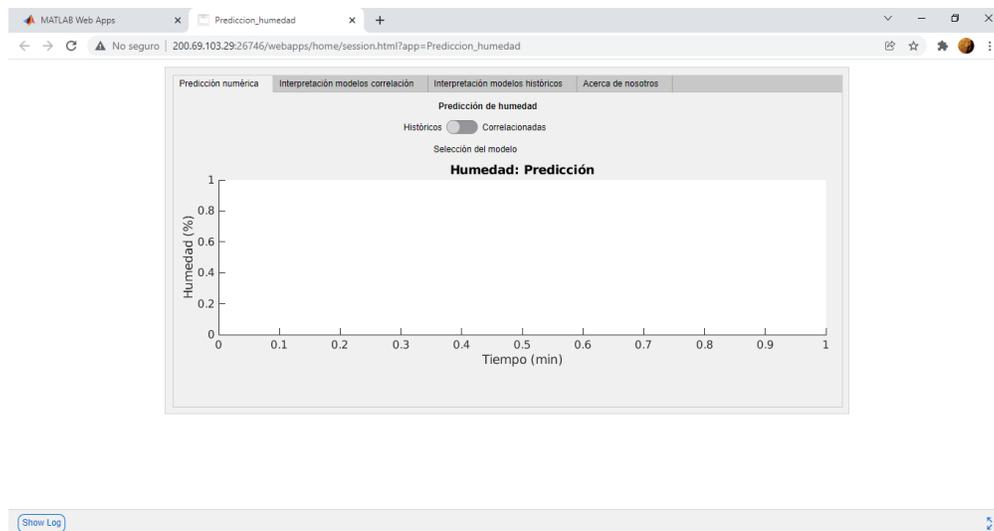


Fig. 9.25: Prototipo como aplicación Web. Elaboración propia. (Entorno MATLAB®)

Capítulo 10

CONCLUSIONES

Como resultado con altos niveles de precisión, representados en la evaluación del éxito de la predicción numérica a través del error obtenido, así como de interpretabilidad la cual se evidencia en el calculo mediante estructuras de descripción cualitativa utilizadas en el lenguaje común y clases de objetos sin límites nítidos pero claramente definidos, se obtienen 12 modelos de predicción de humedad relativa interna en invernaderos basados en sistemas de inferencia difusa optimizados por método híbrido combinando técnicas heurísticas y exactas como lo son algoritmo genético y algoritmo de punto interior respectivamente.

Teniendo en cuenta los datos disponibles, se obtiene tanto un alto nivel de interpretabilidad como un alto grado de precisión con un valor de MSE de $8,200E - 03$ usando un modelo de predicción de humedad relativa interna en invernaderos basada en variables correlacionadas, a través de un sistema de inferencia difusa tipo Mamdani. Por otra parte se obtiene un modelo de predicción basado en tres desplazamientos en el tiempo, con relación a los datos históricos de humedad, con alto grado de precisión representado por un valor de MSE de $2,955E - 04$, a través de un sistema de inferencia difusa tipo ANFIS.

La confiabilidad de los modelos se verifica mediante el alto porcentaje de efectividad representado en un 90,97% para el modelo de predicción basado en variables correlacionadas y un 98,31% para el modelo basado en datos históricos de humedad, que al ser usados en conjunto con procesos de control permiten alcanzar mayores índices de rendimiento en los cultivos

Partiendo de un modelo basado en variables correlacionadas y sistemas de inferencia difusa tipo Mamdani se logró un enfoque altamente interpretable que permite a usuarios que no cuentan con conocimientos especializados en representaciones matemáticas, interpretar fácilmente el comportamiento de la humedad interna, facilitando el seguimiento y control de la variable en el desarrollo de los cultivos en invernadero.

La implementación de los modelos de predicción mediante un prototipo software facilita la interac-

ción directa del usuario y brinda una descripción clara y sencilla del comportamiento de la humedad para su seguimiento y control a través de gráficas e interfaces interactivas que facilitan el manejo e interpretación.

10.1. Principales Aportes

Teniendo en cuenta los resultados alcanzados en el proyecto de investigación y atendiendo a los objetivos propuestos se tienen los siguientes aportes del desarrollo del proyecto de grado:

- Se obtuvo un modelo interpretable, por medio de sistemas de inferencia difusa, que define el comportamiento de la humedad como resultado de la temperatura, CO_2 y humedad del suelo a través de un análisis de correlación de las variables del invernadero y la forma en que estas modifican la humedad.
- Desde dos enfoques se obtuvieron valores de predicción con porcentajes de efectividad por encima del 90%, estos dos enfoques están conformados por 12 modelos con alta precisión e interpretabilidad.
- Los modelos obtenidos presentan altos niveles de precisión, sin afectar la interpretabilidad de los mismos, con la optimización mediante un método híbrido que combina algoritmos genéticos y algoritmo de punto interior.
- El prototipo software definido permite evidenciar la aplicación de los modelos de predicción para cada uno de los enfoques. El acceso a los modelos es permitido a través de una interfaz apoyada en componentes gráficos de usuario haciendo que la utilización de los modelos pueda ser efectuada por personas con conocimientos básicos en sistemas computacionales, brindando información que pueda ser usada por los agricultores para mejorar el rendimiento en relación a la humedad requerida en cultivos.

Capítulo 11

PROSPECTIVA DEL TRABAJO DE GRADO

Este capítulo presenta dos secciones, la primera sección con los productos generados del desarrollo del proyecto de investigación y la segunda con las recomendaciones y los posibles trabajos futuros.

11.1. PRODUCTOS

Esta sección presenta los productos resultado del proceso investigativo, dividiendo los mismos en productos publicados, en revisión y en desarrollo, donde se encuentran artículos publicados en revistas nacionales e internacionales, ponencias en eventos científicos y registro y protección de la propiedad intelectual.

11.1.1. ARTÍCULOS

- Gestión del ambiente del invernadero mediante un microcontrolador electrónico para el cultivo de vegetales. Revista Espacios. ISSN: 0798-1015, publicado.
- Environment humidity and temperature prediction in agriculture using Mamdani inference systems. International Journal of Electrical and Computer Engineering (IJECE). ISSN: 2088-8708, publicado.
- A systematic review of greenhouse humidity prediction and control models using fuzzy inference systems. Advances in Human-Computer Interaction. ISSN: 1687-5893, publicado.
- Predictive model of humidity in greenhouses through fuzzy inference systems applying optimization methods, en desarrollo.

11.1.2. PONENCIAS EN EVENTOS CIENTÍFICOS

- Modelo predictivo de humedad en invernaderos mediante sistemas de inferencia difusa a partir de temperatura, CO_2 y humedad del suelo, en desarrollo.

11.1.3. REGISTRO DE SOFTWARE Y PROPIEDAD INTELECTUAL

- “PredHumidity”, registro de derechos de autor del prototipo de software, en revisión.
- Prototipo de invernadero para el cultivo de vegetales gestionado por un microcontrolador, en desarrollo para posterior estudio con la Oficina de Transferencias de Resultados de Investigación (OTRI) como patente de modelo de utilidad.

11.2. RECOMENDACIONES Y TRABAJOS FUTUROS

Teniendo en cuenta el proceso investigativo desarrollado y los resultados alcanzados se proponen una serie de recomendaciones y posibilidades para la continuidad del proyecto a partir de otros enfoques.

11.2.1. RECOMENDACIONES

A partir de las características de implementación del invernadero considerando las variables de: humedad relativa interna, temperatura interna, humedad del suelo, intensidad de luz, concentración de CO_2 , luminosidad y la activación de ventilación, sistema de riego y sistema de calefacción, se postulan las siguientes recomendaciones:

- Los modelos están diseñados para considerar las variables descritas anteriormente, si es necesario añadir otro actuador o sensor, se debe analizar su correlación entre las variables y revisar si es viable implementar el modelo sin modificaciones.
- Los modelos se desarrollan basados en un cultivo de habichuela, e igualmente fueron contrastados con los datos de un invernadero sin cultivo, mostrando la misma correlación de las variables, por lo cual, si se requiere mejorar la precisión con algún otro cultivo, estos pueden volver a ser entrenados manteniendo la misma configuración de los sistemas de inferencia difusa.

11.2.2. TRABAJOS FUTUROS

Se postulan los siguientes trabajos futuros mostrando diversas opciones de continuidad del proyecto desde otros enfoques:

- Los modelos desarrollados pueden ser utilizados para la gestión de invernaderos automatizados, implementando controladores difusos o controladores predictivos basados en modelos.
- Para aumentar los niveles de precisión manteniendo la interpretabilidad se puede realizar una red de sistemas de inferencia difusa combinando diferentes propuestas de modelos desarrolladas en este documento.
- Debido al comportamiento estacional de la humedad se pueden investigar formas de garantizar un comportamiento con mayor precisión del modelo, ya sea mediante combinaciones de diversos métodos de entrenamiento de los sistemas de inferencia difusa y redes neuronales recurrentes o con el desarrollo de un ajuste automático de los modelos basado en la tendencia del error y un conjunto de n datos históricos.

GLOSARIO

Alpha (α) Intervalo de confianza. Es el grado de certeza (o probabilidad), con el que se desea realizar la estimación de un parámetro a través de un estadístico muestral.

Coefficiente de Asimetría Es la medida que indica la simetría de la distribución de una variable respecto a la media aritmética, indican si hay el mismo número de elementos a izquierda y derecha de la media.

Coefficiente de correlación de Pearson Es una medida que permite conocer el grado de asociación lineal entre dos variables cuantitativas (X, Y)..

Coefficiente de correlación de Spearman Es una medida no paramétrica de la correlación de rango es decir evalúa la relación monótona entre dos variables, donde las variables tienden a cambiar al mismo tiempo, pero no necesariamente a un ritmo constante..

Conjunto difuso Un conjunto difuso es un conjunto sin un límite nítido y claramente definido. Puede contener elementos con solo un grado parcial de pertenencia.

Curtosis La curtosis de una variable estadística aleatoria es una característica de forma de su distribución de frecuencias, puede ser usada para buscar observaciones anómalas y describe que tanto se esta la concentración de valores de la media de la distribución.

Defuzzificación Es el proceso mediante el cual se obtiene un valor cuantificable, a partir de conjuntos difusos y sus correspondientes grados de pertenencia.

Función de activación Define la salida de un nodo dada una entrada o un conjunto de entradas, normalmente el conjunto de valores de salida se encuentra en un rango determinado.

Función de pertenencia Es una función que permite identificar el grado en que cada elemento de un universo dado, pertenece a dicho conjunto.

Fuzzificación Es el proceso mediante el cual se toman las entradas de un sistema de inferencia y se determina el grado al que pertenecen cada uno de los conjuntos difusos apropiados, a través de funciones de pertenencia, equivale a una búsqueda en una tabla o una evaluación de la función.

Grado de pertenencia Corresponde al grado difuso de pertenencia en el conjunto lingüístico calificado (siempre el intervalo de 0 a 1) para una entrada con valor numérico nítido limitado al universo del discurso.

Método de agregación La agregación es el proceso mediante el cual los conjuntos difusos que representan los resultados de cada regla se combinan en un solo conjunto difuso. Se admiten tres métodos integrados: max (máximo), probor (probabilístico OR), sum (suma de los conjuntos de salida de la regla).

Método de implicación Es un método para obtener una ponderación adecuada de las características lingüísticas que se obtienen a partir de un antecedente, que corresponde a un número único, y un consecuente, que hace alusión a un conjunto difuso. Utiliza el método AND: min (mínimo), que trunca el conjunto difuso de salida, o prod (producto), el cual escala el conjunto difuso de salida.

p-value Corresponde al valor de probabilidad determinado por la prueba t de dos muestras que al contrastarse con un intervalo de confianza, permite determinar la validez de una hipótesis nula, establecida previamente, con relación a la distribución de los datos analizados.

Prueba t de dos muestras Prueba si dos muestras independientes provienen de distribuciones normales con varianzas desconocidas pero iguales (u, opcionalmente, desiguales) y la misma media, contra la alternativa de que las medias son desiguales..

Regla de inferencia Se utilizan para formular las declaraciones condicionales que comprenden la lógica difusa a partir de los conjuntos y operadores difusos.

RReliefF Mejora del algoritmo ReliefF que a su vez mejora el algoritmo de selección Relief, este sirve como filtro para selección de características, considerando datos faltantes, múltiples clases y regresión entre los datos..

Superficie de reglas Es un mapa de superficie de salida para el sistema de inferencia difusa para ver la dependencia de una de las salidas en una o dos de las entradas.

BIBLIOGRAFÍA

- Adriyendi. (2018). Fuzzy Logic using Tsukamoto Model and Sugeno Model on Prediction Cost. *I.J. Intelligent Systems and Applications*, 6, 13-21.
- Algarín, C. R., Cabarcas, J. C. & Llanos, A. P. (2017). Low-Cost Fuzzy Logic Control for Greenhouse Environments with Web Monitoring. *Electronics*, 6(4), 71. <https://doi.org/10.3390/electronics6040071>
- Ameen, N. M. & Al-Ameri, J. A. M. (2019). IoT-Based Shutter Movement Simulation for Smart Greenhouse Using Fuzzy-Logic Control, En *2019 12th International Conference on Developments in eSystems Engineering (DeSE)*. <https://doi.org/10.1109/DeSE.2019.00119>
- Ariani, F. & Endra, R. Y. (2013). IMPLEMENTATION OF FUZZY INFERENCE SYSTEM WITH TSUKAMOTO METHOD FOR STUDY PROGRAMME SELECTION, Bandar Lampung.
- Auken, E., Boesen, T. & Christiansen, A. V. (2017). Review of Airborne Electromagnetic Methods With Focus on Geotechnical and Hydrological Applications From 2007 to 2017. En *Advances in Geophysics* (pp. 47-93). Elsevier.
- Baille, M., Laury, J.-C., Baille, A. & Sappe, G. (1984). Influence d'un écran thermique sur le bilan énergétique et le microclimat nocturnes d'une serre. *Agronomie*, 4(4), 327-332. <https://doi.org/10.1051/agro:19840402>
- Ballabrera, J. (2010). *Módulo I: Motores de la Biosfera Capítulo 11 Modelos generales de circulación oceánica* (inf. téc.).
- Baron, J., Vanegas, S. C. & Rocha, C. E. (2020). Gestión del ambiente del invernadero mediante un microcontrolador electrónico para el cultivo de vegetales. *Revista ESPACIOS*, 41(19).
- Boughamsa, M. & Ramdani, M. (2018). Adaptive fuzzy control strategy for greenhouse micro-climate. *International Journal of Automation and Control*, 12(1), 1. <https://doi.org/10.1504/ijaac.2018.10007843>
- Bryan, K. (2017). Rose-Hulman Institute of Technology. <https://www.rose-hulman.edu/%7B~%7Dbryan/lottamath/quasinewton.pdf>
- Caponetto, R., Fortuna, L., Nunnari, G., Occhipinti, L. & Xibilia, M. G. (2000). Soft computing for greenhouse climate control. *IEEE Transactions on Fuzzy Systems*, 8(6), 753-760. <https://doi.org/10.1109/91.890333>
- Czabanski, R., Jezewski, M. & Leski, J. (2017). Introduction to Fuzzy Systems. En P. Prokopowicz, J. Czerniak, D. Mikołajewski, Ł. Apiecionek & D. Śl zak (Eds.), *Theory and Applications of Ordered Fuzzy Numbers A Tribute to Professor Witold Kosiński* (pp. 23-43). Springer.

- Ding, J. T., Tu, H. Y., Zang, Z. L., Huang, M. & Zhou, S. J. (2018). Precise control and prediction of the greenhouse growth environment of *Dendrobium candidum*. *Computers and Electronics in Agriculture*, 151, 453-459. <https://doi.org/10.1016/j.compag.2018.06.037>
- Errahmani, A., yakhlef Majid Benyakhlef, B. & Boumhidi, I. (2009). Greenhouse Model Identification based on Fuzzy Clustering Approach. *ICGST-ACSE Journal*, 9(2), 23-27.
- Faouzi, D., Bibi-Triki, N., Mohamed, B. & Abène, A. (2017). Optimization, modeling and simulation of microclimate and energy management of the greenhouse by modeling the associated heating and cooling systems and implemented by a fuzzy logic controller using artificial intelligence. *Informatika (Slovenia)*, 41(3), 317-331.
- Fourati, F. (2014). Multiple neural control of a greenhouse. *Neurocomputing*, 139, 138-144.
- Gondchawar, N. & Kawitkar, R. S. (2016). IoT based Smart Agriculture. *International Journal of Advanced Research in Computer and Communication Engineering*, 5. <https://doi.org/10.17148/IJARCCE.2016.56188>
- Guerrero-Santana, A., López-Cruz, I., Ruiz-García, A., Fitz-Rodríguez, E. & Salazar-Moreno, R. (2018). Prediction of air temperature and relative humidity in a solar greenhouse dryer using neuro-fuzzy models, En *ASABE 2018 Annual International Meeting*, St. Joseph, MI, American Society of Agricultural; Biological Engineers. <https://doi.org/10.13031/aim.201801493>
- Guo, P., Wang, X. & Han, Y. (2010). The Enhanced Genetic Algorithms for the Optimization Design, Yantai, China, Institute of Electrical; Electronics Engineers.
- Hamidane, H., El Faiz, S., Rkik, I., El Khayat, M., Guerbaoui, M., Ed-Dhhak, A. & Lachhab, A. (2021). Application analysis of ANFIS strategy for greenhouse climate parameters prediction: Internal temperature and internal relative humidity case of study. *E3S Web Conf.*, 297. <https://doi.org/10.1051/e3sconf/202129701041>
- Hamza, A. & Ramdani, M. (2020). Non-PDC Interval Type-2 Fuzzy Model Predictive Microclimate Control of a Greenhouse. *Journal of Control, Automation and Electrical Systems*, 31(1), 62-72. <https://doi.org/10.1007/s40313-019-00532-4>
- Heidari, M. & Khodadadi, H. (2017). Climate control of an agricultural greenhouse by using fuzzy logic self-tuning PID approach, En *ICAC 2017 - 2017 23rd IEEE International Conference on Automation and Computing: Addressing Global Challenges through Automation and Computing*, Institute of Electrical; Electronics Engineers Inc. <https://doi.org/10.23919/IConAC.2017.8082074>
- Hurtado, E. G., Olmedo, A. S., Ortega, J. C. P., Fernandez, M. A. A. & Carillo, U. G. V. (2010). Modeling key parameters for greenhouse using fuzzy clustering technique, En *Proceedings of Special Session - 9th Mexican International Conference on Artificial Intelligence: Advances in Artificial Intelligence and Applications, MICAI 2010*. <https://doi.org/10.1109/MICAI.2010.37>
- Isanta Navarro, R. (s.f.). Annex 1 Introduction to Neural Networks and Adaptive Neuro-Fuzzy Inference Systems (ANFIS). <https://upcommons.upc.edu/bitstream/handle/2099.1/20296/Annex%201%20-%20Introduction%20to%20Adaptive%20Neuro-Fuzzy%20Inference%20Systems%20%7B%5C%7D28ANFIS%7B%5C%7D29.pdf>
- Izquierdo, S. S. & Izquierdo, L. R. (2018). Mamdani Fuzzy Systems for Modelling and Simulation: A Critical Assessment. *Journal of Artificial Societies and Social Simulation (JASSS)*, 21.

- Javadikia, P., Tabatabaeeefar, A., Omid, M., Alimardani, R. & Fathi, M. (2009). Evaluation of intelligent greenhouse climate control system, based fuzzy logic in relation to conventional systems, En *2009 International Conference on Artificial Intelligence and Computational Intelligence, AICI 2009*, IEEE Computer Society. <https://doi.org/10.1109/AICI.2009.494>
- Jian-kun, G., Shun-sheng, W., Jin-yao, L. & Zeng-jin, L. (2014). Simulation and Fuzzy Control of Greenhouse Microclimate Based On Simulink. *Nature Environment and Pollution Technology*, 13(4), 823.
- Klir, G. J. & Yuan, B. (1995). *Fuzzy Sets and Fuzzy Logic Theory and Applications*. New Jersey, Prentice Hall PTR.
- Knapp, R. B. (2007a). *Fuzzy Sets and Pattern Recognition - Adaptive Fuzzy* (inf. téc.).
- Knapp, R. B. (2007b). *Fuzzy Sets and Pattern Recognition - Fuzzy inference systems* (inf. téc.).
- Koutb, M. A., El-Rabaie, N. M., Awad, H. A. & Abd El-Hamid, I. A. (2004). Environmental control for plants using intelligent control systems. *IFAC Proceedings Volumes*, 37(2), 101-106. [https://doi.org/10.1016/s1474-6670\(17\)38698-6](https://doi.org/10.1016/s1474-6670(17)38698-6)
- Lachouri, C., Mansouri, K., Lafifi, M. & Belmeguenai, A. (2016). Adaptive Neuro-Fuzzy Inference Systems for Modeling Greenhouse Climate. *International Journal of Advanced Computer Science and Applications*, 7(1). <https://doi.org/10.14569/ijacsa.2016.070114>
- Lambers, J. (2011a). MAT 419/519 Optimization in Mathematical Programming. <https://www.math.usm.edu/math/lambers/mat419/lecture11.pdf>
- Lambers, J. (2011b). MAT 461/561 Numerical Analysis II. <https://www.rose-hulman.edu/%7B-%7Dbryan/lottamath/quasinewton.pdf>
- Lanfang, P., Wanliang, W. & Qidi, W. (2000). Application of adaptive fuzzy logic system to model for greenhouse climate, En *Proceedings of the 3rd World Congress on Intelligent Control and Automation (Cat. No.00EX393)*. <https://doi.org/10.1109/WCICA.2000.862758>
- Lenka, S. K. & Mohapatra, A. G. (2015). Gradient Descent with Momentum based Neural Network Pattern Classification for the Prediction of Soil Moisture Content in Precision Agriculture, Indore.
- Maher, A., Kamel, E., Enrico, F., Atif, I. & Abdelkader, M. (2016). An intelligent system for the climate control and energy savings in agricultural greenhouses. *Energy Efficiency*, 9(6), 1241-1255. <https://doi.org/10.1007/s12053-015-9421-8>
- Mathews, J. H. (2005). Broyden's Method - Numerical Analysis - Numerical Methods. <http://mathfaculty.fullerton.edu/mathews/n2003/BroydenMethodMod.html>
- MathWorks Inc. (2019). Mamdani and Sugeno Fuzzy Inference Systems - MATLAB and Simulink. <https://www.mathworks.com/help/fuzzy/types-of-fuzzy-inference-systems.html;jsessionid=85440d09d9bbf94114e051a26dae%7B%5C#%7Dd117e2400>
- MathWorks Inc. (2021a). Choosing the Algorithm - Solver-Based Optimization Problem. Recuperado el 8 de diciembre de 2021, desde <https://www.mathworks.com/help/optim/ug/choosing-the-algorithm.html>
- MathWorks Inc. (2021b). Constrained Nonlinear Optimization Algorithms. Recuperado el 8 de diciembre de 2021, desde <https://www.mathworks.com/help/optim/ug/constrained-nonlinear-optimization-algorithms.html>

- MathWorks Inc. (2021c). fmincon Interior-Point Algorithm with Analytic Hessian. Recuperado el 8 de diciembre de 2021, desde <https://www.mathworks.com/help/optim/ug/fmincon-interior-point-algorithm-with-analytic-hessian.html>
- MathWorks Inc. (2021d). genfisOptions - Fuzzy Clustering. Recuperado el 8 de diciembre de 2021, desde <https://www.mathworks.com/help/fuzzy/genfisoptions.html>
- Mehran, K. (2008). Takagi-Sugeno Fuzzy Modeling for Process Control. <https://www.staff.ncl.ac.uk/damian.giaouris/pdf/IA%20Automation/TS%20FL%20tutorial.pdf>
- Morimoto, T. & Hashimoto, Y. (2000). An intelligent control for greenhouse automation, oriented by the concepts of SPA and SFA - An application to a post-harvest process, En *Computers and Electronics in Agriculture*, Elsevier Science Publishers B.V. [https://doi.org/10.1016/S0168-1699\(00\)00133-2](https://doi.org/10.1016/S0168-1699(00)00133-2)
- Mostakim, N., Mahmud, S. & Jewel, K. H. (2020). A Simulation Based Study of A Greenhouse System with Intelligent Fuzzy Logic, En *International Journal of Fuzzy Logic Systems (IJFLS)*. <https://doi.org/10.5121/ijfls.2020.10102>
- Nachidi, M., Benzaouia, A. & Tadeo, F. (2006). Temperature and humidity control in greenhouses using the takagi-sugeno fuzzy model, En *Proceedings of the IEEE International Conference on Control Applications*. <https://doi.org/10.1109/CACSD-CCA-ISIC.2006.4776973>
- Nehra, K., Nehra, V., Hasan, M., Singh, M. & Ahlawat, S. (2015). Fuzzy expert system for greenhouse rose yield prediction. *Ecology, Environment and Conservation*, *21*, 347-352.
- Nocedal, J. & Wright, S. J. (2006). *Numerical Optimization*. Springer.
- Outanoute, M., Lachhab, A., Ed-dahhak, A., Selmani, A., Guerbaoui, M. & Bouchikhi, B. (2015). A neural network dynamic model for temperature and relative humidity control under greenhouse, Agadir.
- Palomo Del Barrio, E. (1992). *DESARROLLO DE UNA METODOLOGÍA TEÓRICO EXPERIMENTAL DE CARACTERIZACIÓN DE INVERNADEROS* (inf. téc.).
- Perangin-angin, M. I., Fitriani, W., Mayasari, N. & Putera Utama Siahaan, A. (2016). Tuition Reduction Determination Using Fuzzy Tsukamoto. *International Journal of Engineering Science Invention*, *5*, 68-72.
- Prakash, O., Kumar, A., Kaviti, A. K. & Kumar, P. V. (2015). Prediction of the rate of moisture evaporation from jaggery in greenhouse drying using the fuzzy logic. *Heat Transfer Research*, *46*(10), 923-935.
- Pressman, R. S. (2019). *SOFTWARE ENGINEERING: A PRACTITIONERS APPROACH* (Novena). McGraw-Hill Education.
- Putti, F. F., Filho, L. R. A. G., Gabriel, C. P. C., Neto, A. B., Bonini, C. d. S. B. & Rodrigues dos Reis, A. (2017). A Fuzzy mathematical model to estimate the effects of global warming on the vitality of *Laelia purpurata* orchids. *Mathematical Biosciences*, *288*, 124-129. <https://doi.org/10.1016/j.mbs.2017.03.005>
- Qiuying, Z., Jianwei, J., Qingji, L. & Rui, H. (2010). Application of ANFIS for modelling and simulation of the greenhouse environment, En *2010 The 2nd International Conference on Industrial Mechatronics and Automation*. <https://doi.org/10.1109/ICINDMA.2010.5538108>

- Ramdani, M., Hamza, A. & Boughamsa, M. (2015). Multiscale fuzzy model-based short term predictive control of greenhouse microclimate, En *Proceeding - 2015 IEEE International Conference on Industrial Informatics, INDIN 2015*, Institute of Electrical; Electronics Engineers Inc. <https://doi.org/10.1109/INDIN.2015.7281931>
- Rao, S. (2009). *Engineering Optimization Theory and Practice*. Hoboken, NJ, John Wiley; Sons Inc.
- Revathi, S. & Sivakumaran, N. (2016). Fuzzy based temperature control of greenhouse, En *IFAC-PapersOnLine*, Elsevier B.V. <https://doi.org/10.1016/j.ifacol.2016.03.112>
- Rodríguez Díaz, F. (2005). *Modelado y control jerárquico de crecimiento de cultivos en invernadero : tesis doctoral*. Universidad de Almería, Servicio de Publicaciones.
- Ross, T. J. (2010). *Fuzzy Logic with Engineering Applications*. John Wiley; Sons, Ltd.
- Rothlauf, F. (2011). Optimization Methods, En *Natural Computing Series*. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-540-72962-4_3
- Saha, S., Moorthi, S., Pan, H.-L., Wu, X., Wang, J., Nadiga, S., Tripp, P., Kistler, R., Woollen, J., Behringer, D., Liu, H., Stokes, D., Grumbine, R., Gayno, G., Wang, J., Hou, Y.-T., Chuang, H.-y., Juang, H.-M. H., Sela, J., ... Goldberg, M. (2010). The NCEP Climate Forecast System Reanalysis. *Bulletin of the American Meteorological Society*, 91(8), 1015-1058. <https://doi.org/10.1175/2010BAMS3001.1>
- Salgado, P. & Cunha, J. B. (2005). Greenhouse climate hierarchical fuzzy modelling. *Control Engineering Practice*, 13(5), 613-628. <https://doi.org/10.1016/j.conengprac.2004.05.007>
- Sampieri, R. H., Fernández Collado, C. & Baptista Lucio, M. d. P. (2014). *Metodología de la Investigación (Sexta)*. México D.F., Mc Graw Hill.
- Shamshiri, R. (2017). Measuring optimality degrees of microclimate parameters in protected cultivation of tomato under tropical climate condition. *Measurement: Journal of the International Measurement Confederation*, 106, 236-244. <https://doi.org/10.1016/j.measurement.2017.02.028>
- Shing, J. & Jang, R. (1993). ANFIS : Adaptive-Network-Based Fuzzy Inference System. *IEEE TRANSACTIONS ON SYSTEMS, MAN, AND CYBERNETICS*, 23, 665-685.
- Taylan, O. (2017). Modelling and analysis of ozone concentration by artificial intelligent techniques for estimating air quality. *Atmospheric Environment*, 150, 356-365. <https://doi.org/https://doi.org/10.1016/j.atmosenv.2016.11.030>
- Trabelsi, A., Lafont, F., Kamoun, M. & Enea, G. (2007). Fuzzy identification of a greenhouse. *Applied Soft Computing*, 7(3), 1092-1101. <https://doi.org/https://doi.org/10.1016/j.asoc.2006.06.009>
- Vanegas, S. C. (2021a). Greenhouse actuators dataset. *Bogotá D.C.* Recuperado el 21 de noviembre de 2021, desde <https://thingspeak.com/channels/1385852>
- Vanegas, S. C. (2021b). Greenhouse Dataset stringless blue lake beans Cultivation. *Bogotá D.C.* Recuperado el 21 de noviembre de 2021, desde <https://thingspeak.com/channels/1342776>
- Vanegas, S. C. (2021c). Greenhouse Dataset Without Cultivation. *Bogotá D.C.* Recuperado el 21 de noviembre de 2021, desde <https://thingspeak.com/channels/1397640>
- Wang, L., Wang, B. & Zhu, M. (2020). Multi-Model Adaptive Fuzzy Control System Based on Switch Mechanism in a Greenhouse. *Applied Engineering in Agriculture*, 36(4), 549-556. <https://doi.org/10.13031/aea.13837>

- Witten, I. H., Frank, E., Hall, M. & Pal, C. J. (2017). *Data Mining Practical Machine Learning Tools and Techniques*. Cambridge, MA, Elsevier Inc.
- Yue, Y., Quan, J., Zhao, H. & Wang, H. (2018). The Prediction of Greenhouse Temperature and Humidity Based on LM-RBF Network, Changchun.